

UNIVERSIDAD NACIONAL FEDERICO VILLARREAL

FACULTAD DE INGENIERÍA DE SISTEMAS

ESCUELA DE POST GRADO

**Redes neuronales para el reconocimiento de la calidad
morfológica de mangos exportables para la empresa
Biofruit del Perú S.A.C.**

TESIS

para optar el grado académico de Doctor en Ingeniería

AUTOR

Hugo Froilán Vega Huerta

Lima – Perú

2011

Dedicatoria:

A mi madre, por darme la fuerza espiritual.

A mi padre, que desde el cielo ilumina mis caminos.

A mi esposa, por su compañía y dedicación constante.

A mis hijos Robin y Verito por ser la alegría y razón de mi vida,

A mis hermanos y sobrinos por brindarme su apoyo e incentivo permanente,

AGRADECIMIENTOS

Al mi asesor de tesis Dr. Segundo Sánchez Sotomayor, por su gran apoyo y aporte que me permitieron concluir exitosamente el presente trabajo.

A los Doctores Higinio Flores y Ciro Rodríguez, en reconocimiento a sus invalorable y acertadas críticas constructivas, recomendaciones y sugerencias tanto metodológicas como temáticas, que me permitieron realizar importantes mejoras en mi tesis.

Al Dr. Javier Gamboa Cruzado, por que gracias a su gran dominio sobre el tema de Redes Neuronales me supo brindar aportes muy significativos que me permitieron superar aspectos débiles de mi tesis.

Al Ingeniero Víctor Bustamante, por su apoyo profesional en la programación y desarrollo del software que presentamos en esta tesis.

Al Ingeniero Samuel Torres Gerente General de Biofruit del Perú S.A.C. por brindarme su gran apoyo en lo que respecta a la información sobre las características de la calidad de los mangos de exportación, así como los datos referentes al proceso de control de calidad y estadísticas de producción y exportación.

A todos mis colegas y amigos que contribuyeron a que este proyecto concluya satisfactoriamente.

RESUMEN

En esta tesis presentamos un Sistema Experto que permite reconocer los mangos cuyas formas cumplen con los estándares de calidad exigidos por clientes de Estados Unidos y Europa.

El software está basado en el proceso de imágenes digitales de mangos mediante redes neuronales artificiales.

Primeramente seleccionamos una muestra de mangos exportables; luego, utilizando el sistema, tomamos una imagen digital de cada mango, con dichas imágenes entrenamos una Red Neuronal para que reconozca acertadamente todos los elementos de la muestra. Luego, procedemos con las pruebas de reconocimiento con otros mangos de calidad y con los que no presentan dichas características, y si el software los reconoce acertadamente, diremos que hemos cumplido con nuestro objetivo.

Palabras Clave:

Redes neuronales artificiales, entrenamiento de redes neuronales, reconocimiento de patrones, reconocimiento de calidad del mango

ABSTRACT

In this thesis we present an Expert System that allow recognize the mangoes which forms meet the quality standards required by customers in the U.S. and Europe.

The software is based on digital images processing of mangoes using artificial neural networks.

At first we select a sample of export mangoes, then using the system; we take a digital image of each mango and with such images we train a neural network until it is able to recognize correctly all elements of the sample. Then we will proceed with the recognition tests of other quality mangoes and those without these features, and if the software recognizes it properly, we can say we have fulfilled our objective.

Keywords:

Artificial neural networks, training of neural networks, pattern recognition, recognition of quality mangoes

Í N D I C E

| | |
|--|----------|
| INTRODUCCIÓN..... | 1 |
| CAPÍTULO I. EL PROBLEMA..... | 3 |
| 1.1 SELECCIÓN DEL PROBLEMA..... | 3 |
| 1.1.1 Antecedentes de la Empresa Biofruit del Perú..... | 3 |
| 1.1.2 Descripción del Problema..... | 5 |
| 1.2 FORMULACIÓN DEL PROBLEMA..... | 6 |
| 1.2.1 Problema General..... | 6 |
| 1.2.2 Problemas Específicos..... | 6 |
| 1.3 OBJETIVOS DE LA INVESTIGACIÓN..... | 6 |
| 1.3.1 Objetivo General..... | 6 |
| 1.3.2 Objetivos Específicos..... | 6 |
| 1.4 HIPÓTESIS, VARIABLES E INDICADORES..... | 7 |
| 1.4.1 Hipótesis General..... | 7 |
| 1.4.2 Hipótesis Específicas..... | 7 |
| 1.4.3 Variable Independiente..... | 7 |
| 1.4.4 Variables Dependientes..... | 7 |
| 1.4.5 Indicadores..... | 7 |
| 1.5 JUSTIFICACIÓN DE LA INVESTIGACIÓN..... | 8 |
| 1.6 LIMITACIONES DE LA INVESTIGACIÓN..... | 9 |
| 1.7 ANTECEDENTES BIBLIOGRÁFICOS DE LA INVESTIGACIÓN..... | 9 |

| | |
|--|-----------|
| CAPÍTULO II. MARCO TEÓRICO..... | 15 |
| 2.1 REDES NEURONALES ARTIFICIALES (RNA)..... | 15 |
| 2.1.1 Definición de Redes Neuronales Artificiales..... | 15 |
| 2.1.2 Elementos Básicos de una Neurona..... | 17 |
| 2.1.3 Elementos de una Red Neuronal Artificial..... | 20 |
| 2.1.4 Principales Características de las Redes Neuronales Artificiales.. | 20 |
| 2.2 CLASIFICACIÓN DE LAS RNA..... | 21 |
| 2.2.1 Según su Arquitectura..... | 21 |
| 2.2.1.1 Con Conexiones hacia Adelante..... | 21 |
| 2.2.1.2 Con Conexiones hacia Atrás..... | 23 |
| 2.2.2 Según Su Aprendizaje..... | 23 |
| 2.2.2.1 Aprendizaje Supervisado..... | 23 |
| 2.2.2.2 Aprendizaje No Supervisado..... | 24 |
| 2.2.3 Según su Aplicación..... | 24 |
| 2.3 PARÁMETROS DE UNA RED NEURONAL..... | 25 |
| 2.3.1 Parámetros Topológicos..... | 25 |
| 2.3.2 Algoritmo de Aprendizaje..... | 25 |
| 2.4 RNA TIPO PERCEPTRÓN MULTICAPA..... | 26 |
| 2.5 ALGORITMO BACKPROPAGATION..... | 27 |
| 2.5.1 Descripción..... | 27 |
| 2.5.2 Presentación del Algoritmo Backpropagation..... | 28 |
| 2.5.3 Principales Problemas del Backpropagation..... | 29 |
| 2.5.4 Tasa de Aprendizaje..... | 30 |
| 2.5.5 Término de Inercia..... | 30 |
| 2.5.6 Factores que Influyen en el Rendimiento del Aprendizaje..... | 30 |
| 2.6 RECONOCIMIENTO DE PATRONES..... | 32 |
| 2.6.1 Definición..... | 32 |
| 2.6.2 Sistema Básico de Reconocimiento de Patrones..... | 32 |
| 2.6.2.1 Sensor..... | 33 |
| 2.6.2.2 Extracción de Características..... | 33 |
| 2.6.2.3 Selección de Variables..... | 34 |
| | 35 |

| | | |
|---------|--|----|
| 2.6.2.4 | Clasificación..... | |
| 2.7 | EXPORTACIÓN..... | 36 |
| 2.7.1 | Concepto y Tipos de Exportación..... | 36 |
| 2.7.2 | Balanza Comercial..... | 36 |
| 2.7.3 | Terminologías del Comercio Internacional..... | 37 |
| 2.7.4 | Codex Alimentarius..... | 38 |
| 2.8 | LA EXPORTACIÓN EN EL PERÚ..... | 39 |
| 2.8.1 | Evolución de la Exportación en la Última Década..... | 39 |
| 2.8.2 | Exportaciones Tradicionales y Exportaciones no Tradicionales.... | 41 |
| 2.8.3 | Oportunidades para los Exportadores..... | 41 |
| 2.8.4 | Evolución de la Exportación de Frutas..... | 41 |
| 2.9 | EXPORTACION DEL MANGO EN EL PERU..... | 43 |
| 2.9.1 | Tipos y Características de los Mangos Exportables..... | 43 |
| 2.9.2 | Cadena de Valor Agregado del Mango..... | 43 |
| 2.9.3 | Principales Países Importadores de Mangos Frescos..... | 44 |
| 2.9.4 | Principales Destinos del Mango Fresco Peruano..... | 44 |
| 2.9.5 | Evolución de la Producción vs Exportación de Mangos Frescos.... | 44 |
| 2.9.6 | Exportación de Mangos Frescos en Toneladas y en Dólares..... | 45 |
| 2.9.7 | Evolución de la Producción de Mangos por Departamentos..... | 46 |
| 2.9.8 | Exportación por Tipos de Mango..... | 46 |
| 2.9.9 | Costos de Exportación de Mango Fresco..... | 47 |
| 2.9.10 | Estándares Nacionales e Internacionales de Mangos Exportables.. | 48 |
| 2.10 | PRODUCTOS..... | 50 |
| 2.10.1 | Definición de Productos:..... | 50 |
| 2.10.2 | Control de Calidad..... | 50 |
| 2.10.3 | Aseguramiento de Calidad:..... | 51 |
| 2.10.4 | Marco Normativo Legal..... | 51 |
| 2.11 | EVALUACIÓN COMPARATIVA DE MÉTODOS DE RECONOCIMIENTO DE PATRONES..... | 52 |
| 2.11.1 | Criterios de Comparación..... | 52 |
| 2.11.2 | Cuadro Comparativo de Métodos para el Reconocimiento de Patrones..... | 53 |

| | | |
|----------------------|---|-----------|
| 2.12 | EVALUACIÓN COMPARATIVA DE REDES NEURONALES EN EL RECONOCIMIENTO DE PATRONES..... | 53 |
| 2.12.1 | Criterios de Comparación..... | 53 |
| 2.12.2 | Cuadro Comparativo de Modelos de RNA en el Reconocimiento de Patrones..... | 55 |
| CAPÍTULO III. | MÉTODO..... | 56 |
| 3.1 | TIPO DE LA INVESTIGACIÓN..... | 56 |
| 3.2 | DISEÑO DE LA INVESTIGACIÓN..... | 57 |
| 3.3 | ESTRATEGIA DE LA PRUEBA DE LA HIPÓTESIS..... | 58 |
| 3.4 | POBLACIÓN..... | 58 |
| 3.5 | MUESTRA PARA EL ENTRENAMIENTO DE LA RNA..... | 59 |
| 3.5.1 | Descripción de la Muestra..... | 59 |
| 3.5.2 | Selección de la Muestra..... | 59 |
| 3.6 | GENERAR LOS DATOS DE ENTRADA DE LA RNA A PARTIR DE LA MUESTRA SELECCIONADA..... | 61 |
| 3.6.1 | Representación Funcional de las RNA y los Datos de E/Salida.... | 61 |
| 3.6.2 | Tomar las Imágenes Digitales de los Elementos de la Muestra.... | 63 |
| 3.6.3 | Convertir Imágenes en Datos Binarios..... | 64 |
| 3.6.3.1 | Superponer a cada Imagen una Matriz Bidimensional.... | 64 |
| 3.6.3.2 | Obtener el Borde de la Imagen en la Matriz..... | 64 |
| 3.6.3.3 | Generar Matriz con Información Binaria..... | 65 |
| 3.6.3.4 | Generar Vector Lineal con Información Binaria..... | 66 |
| 3.6.3.5 | Almacenar los Vectores Lineales en una Tabla..... | 71 |
| 3.7 | ARQUITECTURA DE LA RNA..... | 72 |
| 3.7.1 | Número de Neuronas de en la Capa de Entrada..... | 72 |
| 3.7.2 | Número de Neuronas en la Capa de Salida..... | 72 |
| 3.8 | GENERAR LOS DATOS DE SALIDA DE LA RNA A PARTIR DE LA MUESTRA SELECCIONADA..... | 73 |
| 3.9 | GENERAR LA BASE DE ENTRENAMIENTO DE LA RNA..... | 74 |
| 3.9.1 | Representar en una Tabla el Conocimiento de los Expertos..... | 74 |
| | | 75 |

| | | |
|----------|--|----|
| 3.9.2 | Generar la Base de Entrenamiento..... | |
| 3.10 | ENTRENAMIENTO DE RNA EN EL RECONOCIMIENTO DE | |
| | MANGOS..... | 76 |
| 3.10.1 | Primer Entrenamiento..... | 76 |
| 3.10.1.1 | Ingreso de Parámetros..... | 77 |
| 3.10.1.2 | Análisis del Resultado..... | 78 |
| 3.10.2 | Entrenamiento Óptimo..... | 79 |
| 3.10.2.1 | Ingreso de Parámetros..... | 79 |
| 3.10.2.2 | Análisis del Resultado..... | 80 |
| 3.11 | PRUEBA DE LA EFICIENCIA DE LA RNA ENTRENADA EN EL | |
| | RECONOCIMIENTO DE MANGOS EXPORTABLES..... | 81 |
| 3.11.1 | Elección de los Mangos a ser Reconocidos..... | 81 |
| 3.11.2 | Generar Datos de Reconocimiento..... | 82 |
| 3.11.3 | Proceso de Reconocimiento de Mangos Exportables..... | 82 |
| 3.11.4 | Interpretación de los Datos de Salida..... | 83 |

CAPÍTULO IV. SISTEMA EXPERTO PARA RECONOCER

| | | |
|-------|---|-----------|
| | MANGOS EXPORTABLES USANDO RNA..... | 86 |
| 4.1 | DESCRIPCIÓN DEL SISTEMA..... | 86 |
| 4.2 | MÓDULOS DEL SISTEMA..... | 87 |
| 4.2.1 | Módulo para Fijar Parámetros de Binarización de Imágenes..... | 87 |
| 4.2.2 | Módulo de Entrenamiento de la RNA..... | 87 |
| 4.2.3 | Módulo de Reconocimiento de Mangos Exportables..... | 87 |
| 4.2.4 | Módulo de Estadísticas de Reconocimientos de Mangos..... | 87 |
| 4.3 | DEMOSTRACION DEL FUNCIONAMIENTO DEL SISTEMA..... | 88 |
| 4.3.1 | Módulo para Fijar Parámetros de Binarización de Imágenes..... | 88 |
| 4.3.2 | Módulo de Entrenamiento de la RNA..... | 89 |
| 4.3.3 | Módulo de Reconocimiento de Mangos Exportables..... | 91 |
| 4.3.4 | Módulo de Estadísticas de Reconocimientos de Mangos..... | 92 |
| 4.4 | CLASIFICACIÓN DE MANGOS CON EL SISTEMA EXPERTO | |
| | PARA LA PRUEBA DE LA HIPÓTESIS..... | 93 |
| | | 93 |

| | | |
|---|---|------------|
| 4.4.1 | Muestra de Mangos para ser Clasificados..... | |
| 4.4.2 | Datos Generados por Expertos..... | 93 |
| 4.4.3 | Datos Proporcionados por el Personal Asignado al Proceso de Clasificación..... | 93 |
| 4.4.4 | Datos Proporcionados por el Sistema Experto..... | 95 |
| CAPÍTULO V. ANÁLISIS DE RESULTADOS..... | | 96 |
| 5.1 | RESUMEN DE LOS RESULTADOS DE CLASIFICACIÓN..... | 96 |
| 5.2 | ANÁLISIS COMPARATIVO DE LOS RESULTADOS DE CLASIFICACIÓN, PRUEBA DE LA HIPÓTESIS..... | 98 |
| CAPÍTULO VI. CONCLUSIONES Y RECOMENDACIONES..... | | 99 |
| 6.1 | CONCLUSIONES..... | 99 |
| 6.2 | RECOMENDACIONES..... | 100 |
| REFERENCIAS BIBLIOGRÁFICAS..... | | 101 |
| ANEXOS..... | | 103 |
| Anexo A. Matriz de Consistencia..... | | 104 |
| Anexo B. Clasificación de las RNA..... | | 105 |
| Anexo C. Norma del CODEX para el Mango (Codex Stan 184-1993)..... | | 106 |

INTRODUCCIÓN

El uso computacional de las Redes Neuronales Artificiales (RNA) viene creciendo exponencialmente, ya que mediante su empleo se encuentran cada vez más soluciones de problemas complejos en las diferentes áreas del conocimiento humano, no como una secuencia de pasos, sino como la evolución de sistemas computacionales inspirados en el cerebro humano y que por tanto dotados de cierta inteligencia operan de forma paralela.

Las RNA deben su denominación a su similitud con el modelo de procesamiento neuronal humano, éstas intentan imitar características propias de los humanos de memorizar y asociar hechos. Las redes neuronales son un modelo artificial y simplificado del cerebro humano, capaz de adquirir conocimiento y de resolver problemas a través de la experiencia.

Entre las soluciones que han revolucionado el avance de la tecnología empleando redes neuronales tenemos el reconocimiento de patrones tales como el reconocimiento óptico de caracteres, de huellas digitales, de rostros, el reconocimiento de voz, el control y la optimización de procesos, la predicción del comportamiento organizacional, fenómenos naturales, etc. Por otro lado, en nuestro país se observa, que en los últimos años, las cifras en el rubro de la agro-exportación, han tenido un crecimiento muy importante, específicamente en la exportación de mangos; según las cifras del Ministerio de Agricultura, hemos crecido de 25,000 toneladas en el año 2000 a más de 100,000 toneladas en el 2010.

Sin embargo también se observa que, en las empresas exportadoras, muchos procesos, entre ellos la selección de mangos exportables, es realizado manualmente operarios o trabajadores, lo que inevitablemente conlleva a un índice alto de margen de error.

Por esta razón tomamos como objetivo de esta tesis diseñar una Red Neuronal Artificial que mediante el proceso de reconocimiento de patrones, sea capaz de aprender a reconocer los mangos exportables, diferenciándolos de los no exportables, con el propósito de reducir el margen de error generado por los procesos de selección manual.

El desarrollo del presente trabajo, para su mejor comprensión ha sido dividido en seis capítulos los mismos que los describimos a continuación:

En el Capítulo I se describe El Problema, sus antecedentes, los objetivos, las hipótesis, la justificación y la delimitación de la investigación. En el Capítulo II se presenta el Marco Teórico, es decir los conceptos requeridos para abordar el desarrollo del proyecto. En el Capítulo III presentamos el Método de la investigación, donde presentamos la investigación propiamente dicha, desde la descripción de la población, la muestra, hasta el entrenamiento de la RNA y el reconocimiento de mangos de exportación. En el Capítulo IV presentamos el Sistema Experto para reconocer los mangos exportables y mostramos todas sus funcionalidades. En el Capítulo V presentamos el Análisis de Resultados de nuestra investigación y presentamos la prueba de la hipótesis. Finalmente, en el Capítulo VI mostramos las Conclusiones y Recomendaciones realizadas en base a los resultados obtenidos.

Al concluir nuestro proyecto consideramos haber logrado tres importantes aportaciones, la primera es haber logrado obtener los patrones de calidad morfológica de los mangos de exportación, la segunda es haber logrado construir una RNA capaz de reconocer dichos patrones, y la tercera aportación es la implementación del sistema experto que permite realizar automáticamente los procesos de entrenamiento de la RNA y el reconocimiento de los mangos de exportación, así mismo la generación de estadísticas requeridas por la empresa Biofruit.

CAPÍTULO I

EL PROBLEMA

1.1 SELECCIÓN DEL PROBLEMA

1.1.1 Antecedentes de la Empresa Biofruit

Desde el año de su fundación, 2004 hasta la actualidad, Biofruit del Perú S.A.C. (en adelante Biofruit) se dedica a la producción, empaque y comercialización de productos hortofrutícolas (frutas, hortalizas, tubérculos) entre ellos el mango.

Biofruit es una organización con gestión e infraestructura moderna, con altos niveles de calidad y visión emprendedora que busca satisfacer sus clientes y atender mercados altamente exigentes.

En la campaña de exportación de mango de octubre 2006 a marzo 2007, empacó 3 millones de cajas de 4.25 kg cada caja, a los mercados de USA y Europa, mientras que en la campaña de octubre 2007 a marzo 2008, exportó 4 millones de cajas equivalente a un volumen total de 4,000 toneladas, es decir que tuvo un crecimiento aproximado del 30%.

Asimismo, la planta de empaque se está innovando continuamente, contando a la fecha con calibradora electrónica, enceradora automática, cámara de refrigeración para 30 contenedores, entre otros, que permiten un proceso de empaque oportuno y confiable.

Para la clasificación del mango se **realizan inspecciones visuales mediante operadores humanos** ubicados a los costados de la cinta transportadora, de la que retiran los mangos que consideran no válidos, como se puede apreciar en la siguiente figura.



Figura 1.1: Selección de Mangos por Operadores Humanos.

La inspección basada en operadores humanos presenta dos problemas importantes: la falta de homogeneidad en la inspección y una tasa importante de errores de clasificación asociados al cansancio, se afirma que el 10% de los costos de producción son debidos a fallos de los inspectores humanos, se calcula que la eficiencia de inspección que ofrecen los operarios es sólo de aproximadamente 80%. Todo esto hace que actualmente la empresa busque alternativas más eficientes para automatizar los procesos de inspección.

La automatización del proceso de inspección no es una tarea trivial. Las normativas asociadas a la producción del mango, tienen estándares de calidad

para la exportación; cada nivel de calidad está delimitado por un porcentaje máximo de mangos defectuosos en forma color y peso.

Hoy en día la empresa enfrenta nuevos retos al entrar a mercados más exigentes, por lo que requiere contar con urgencia con una solución que le permita reemplazar el proceso actual de inspección humana con otro que le permita una eficiencia cercana al 100%.

1.1.2 Descripción del Problema.

En los antecedentes contextuales de la empresa exportadora de mangos Biofruit, observamos que el **proceso de clasificación de mangos realizado a través de la inspección visual de operadores humanos genera un margen de error aproximado del 20% y que el 10% de los costos de producción se deben a dichos errores.**

Teniendo en cuenta que el precio promedio del kg de mango exportado es de 1.04 dólares, de los cuales 0.5 corresponde a costos de producción. Por lo tanto, en las 4 mil toneladas exportadas en el periodo 2007-2008 las pérdidas (el 10 % del costo de producción de todo lo exportado) habrían ascendido a:

$$\text{Pérdidas} = 10 \% * (4,000 \text{ TM} * 0.5 \text{ dólares/kg}) = 200 \text{ Mil dólares}$$

Es decir que las pérdidas debido al elevado margen de error en la clasificación manual de los mangos ascienden aproximadamente a los 200 mil dólares anuales.

1.2 FORMULACIÓN DEL PROBLEMA

1.2.1 Problema General¹

¿De qué manera la empresa Biofruit puede reducir su margen de error en el reconocimiento de la calidad morfológica de mangos exportables del 20% a menos del 5%?

1.2.2 Problemas Específicos

- a. ¿De qué manera se generan los patrones morfológicos que identifican a los mangos exportables?
- b. ¿De qué manera se diseña una RNA para que reconozca los patrones morfológicos de los mangos exportables?
- c. ¿De qué manera las Redes Neuronales permiten el Reconocimiento de la Calidad Morfológica de mangos exportables?

1.3 OBJETIVOS DE LA INVESTIGACIÓN

1.3.1 Objetivo General

Entrenar una Red Neuronal para ser capaz de reconocer la calidad morfológica de los mangos de exportación con un margen de error menor al 5%.

1.3.2 Objetivos Específicos

- a. Explicar de qué manera se generan los patrones morfológicos que identifican a los mangos exportables.
- b. Explicar de qué manera se diseña una RNA para que reconozca los patrones morfológicos de los mangos exportables.
- c. Explicar de qué manera las Redes Neuronales permiten el Reconocimiento de la Calidad Morfológica de mangos exportables.

¹ Ver Matriz de Consistencia en el Anexo A.

1.4 HIPÓTESIS, VARIABLES e INDICADORES

1.4.1 Hipótesis

Un **Sistema Experto** basado en Redes Neuronales puede **reconocer la calidad morfológica de los mangos exportables**, con un margen de error menor al 5%.

1.4.2 Variable Independiente

X = Sistema Experto Basado en Redes Neuronales

1.4.3 Variable Dependiente

Y = Reconocimiento de la Calidad Morfológica de mangos exportables

1.4.4 Indicadores

| VARIABLES | INDICADORES |
|--|--------------------------------|
| Variable Independiente X = Sistemas Expertos Basados en R.N. | · Uso (Sí, No) |
| Variable Dependiente Y = Reconocimiento de la Calidad Morfológica de mangos exportables | · Margen de error (%) |

Tabla 1.1: Indicadores para las Variables Elegidas.

1.5 JUSTIFICACIÓN DE LA INVESTIGACIÓN

Desde el punto de vista científico, desarrollaremos una metodología para generar los patrones morfológicos de los mangos exportables los mismos que serán luego convertidos en datos de entrada para el entrenamiento de una red neuronal; así mismo mostraremos detalladamente tanto el proceso de entrenamiento como el proceso reconocimiento de los mangos exportables, esta metodología luego podrá ser aplicada a la palta u otros frutos en general.

Desde el punto de vista de optimización de procesos, con la implementación del Sistema Experto basado en RNA para el Reconocimiento de mangos exportables, el margen de error que esperamos alcanzar será menor al 5% frente al margen de error actual del 20% generado por el reconocimiento manual realizado por el personal de la empresa Biofruit, lo que representa aproximadamente una reducción del margen de error del 15%.

Desde el punto de vista rentable, una optimización del 15% en el margen de error de clasificación de los mangos, que se lograría con el Sistema Experto significaría para Biofruit un incremento del 15% en la exportación, es decir **el 15% de 4,000 toneladas = 600 toneladas**. Si reflejamos este análisis a las cifras de exportación nacional de mangos (100,000 toneladas por año) se podría alcanzar un incremento en la exportación de 15% de 100,000 toneladas = 15,000 toneladas, lo que representaría para el país un **ingreso adicional aproximado de 15 millones de dólares al año**.

1.6 LIMITACIONES DE LA INVESTIGACIÓN

La calidad de los mangos exportables está asociada a parámetros tales como: tamaño, color, sabor, olor, forma, consistencia, aspecto, estado de madurez, etc. Sin embargo, la presente investigación, solamente hará referencia a la forma de los mangos como atributo de calidad de exportación. Por ello, a lo largo del presente trabajo, nos referiremos a la calidad del mango en base a su forma como **Calidad Morfológica del Mango**.

1.7 ANTECEDENTES BIBLIOGRÁFICOS DE LA INVESTIGACIÓN

A continuación comentaremos respecto a la bibliografía consultada que nos ha permitido abordar nuestro proyecto brindándonos tanto los conceptos básicos como los más avanzados, así como resultados de casos investigados.

a) *Handbook of Neural Computation of Oxford University Press*

En 1997 la Oxford University Press publicó “Handbook of Neural Computation - Release 97/1” una de las versiones más completas sobre el tema de REDES NEURONALES ARTIFICIALES. En su redacción participaron muchos especialistas reconocidos mundialmente entre los cuales podemos citar a John Taylor quien actualmente es Presidente de la Sociedad Internacional de Redes Neuronales y Director del Computational Neuroscience Group; Michael Arbib, director del Proyecto de Neurociencias en la University of Southern California.

Lo majestuoso y trascendente de esta publicación es que cada capítulo fue escrito por un especialista experto en dicho tema.

A continuación podemos apreciar algunos capítulos con sus respectivos autores.

- A1.1 The historical background - J. Taylor.
- A1.2 The biological and psychological background - Michael Arbib.

- B1.3 Hopfield networks – Michael Arbib.
- B1.6 A note on nonlinearity and continuity - Michael Arbib.
- B3.2 Characteristics of neural network models - James Noyes.
- B3.5 Training and generalization - James Noyes.
- B4.6 Data representation properties - Thomas Jackson.
- B4.10 Complex representation issues - Thomas Jackson.
- B5.3 Designing analyzable networks - Stephen Luttrell.
- E1.2 Neural network adaptations to hardware - Perry Moerland and Emile Fiesler.
- G3.3 Characterization of chaotic signals using fast learning neural networks - Shawn Pethel and Charles Bowden.
- G4.3 A neural network classifier for chromosome analysis - Jim Graham.

Como se puede apreciar, en esta publicación se encuentran desde las definiciones y conceptos básicos hasta resultados de trabajos de investigación más avanzados, en los cuales, los mismos autores participan como directores de grupos de investigación.

Finalmente es importante resaltar sobre este libro que todos los autores que han participado, son científicos en diferentes áreas como computación, matemática, física, psicología, biología, robótica, mecánica, medicina, neurociencia, lingüística, etc. con publicaciones propias en su área.

b) Reconocimiento de Patrones-Laboratorio de Ingeniería-Universidad la Salle-México

Investigadores del Laboratorio de Ingeniería de la Universidad la Salle de México, En el año 2009, publicaron un trabajo titulado Reconocimiento de Patrones en el cual presentan de manera magistral todos los conceptos teóricos para poder trabajar en el reconocimiento de patrones y acertadamente presentan a manera de ejemplos una recopilación de trabajos realizados en el mundo y en su país (México), entre los que se pueden resaltar los siguientes.

En el mundo

- Patrones Musicales - Raymond Kurzweil - New York.
- Fundamento del Reconocimiento de patrones: Programa Integral de Formación de Especialistas - Cuba.
- Reconocimiento de Patrones Biométricos y Redes Neuronales - China.

En México

- Modelos de cirugía asistida por computadora a partir de sus trabajos sobre tecnología con imágenes – UNAM.

c) **Pattern Recognition - Sergios Theodoridis & Konstantinos Koutroumbas**

Los investigadores griegos Sergios Theodoridis y Konstantinos Koutroumbas, en el año 2009 publicaron la cuarta edición de su libro Pattern Recognition, este libro destaca por que tiene todo el material teórico y práctico para el reconocimiento de patrones, el mismo que está dividido en los siguientes capítulos:

- Clasificadores Basado en la Teoría de la Decisión de Bayes.
- Clasificadores Lineales.
- Clasificadores no Lineales.
- Selección de Funciones.
- Función de Generación: Transformación Lineal.
- Función de Generación: Plantilla de Verificación.
- Clasificación Dependiente del Contexto.
- Sistema de Evaluación.

d) **Redes Neuronales Artificiales y sus Aplicaciones - Xabier Basogain Olabe.**

El autor Xabier Basogain Olabe es profesor del Dpto. Ingeniería de Sistemas y Automática - Escuela Superior de Ingeniería de Bilbao - UPV-EHU (Universidad del País Vasco/ Euskal Herriko Unibertsitatea). El libro es muy interesante porque permite conocer el fundamento teórico de las RNA y termina explicando algunas aplicaciones como por ejemplo: El análisis financiero, procesamiento de imágenes, procesamiento de voz, etc. A continuación mostramos los capítulos más resaltantes del libro.

- Fundamentos de las Redes Neuronales Artificiales.
- Selección de las Redes Neuronales Artificiales.
- Las primeras Redes Neuronales Artificiales.
- Red Backpropagation.
- Red Self Organizing Map y Red Counterpropagation.
- Red Hopfield y Red Bidirectional Associative Memory.
- Red Adaptive Resonance Theory.
- Aplicaciones de las Redes Neuronales Artificiales.
- Lógica Difusa y Redes Neuronales Artificiales.

e) **Tesis Doctoral - Redes Neuronales Artificiales Aplicadas al Análisis de Datos**

De Juan José Montañó Moreno - Universitat de les Illes Balears (UIB), Facultad de Psicología, Palma de Mallorca, 2002.

Esta tesis describe tres líneas de investigación en torno a la aplicación de las redes neuronales artificiales en el ámbito del análisis de datos, estas líneas son las siguientes: el análisis de datos aplicado a conductas adictivas, el análisis de supervivencia, y el estudio del efecto de las variables de entrada en una red neuronal.

En el campo de las conductas adictivas, se creó una red neuronal para la clasificación de sujetos consumidores y no consumidores de éxtasis a

partir de 25 ítems agrupados en cinco categorías temáticas. Un análisis de sensibilidad sobre el modelo de red neuronal, permitió identificar los factores de riesgo asociados al consumo de éxtasis.

En base a los resultados de esta investigación, el autor ha realizado varias publicaciones entre las que destaca “Predicción del consumo de éxtasis a partir de redes neuronales artificiales”, artículo publicado en la revista ADICCIONES que está indexada la base de datos Social Sciences Citation Index (SSCI).

f) **Tesis Doctoral - Técnicas de Reconocimiento Facial mediante Redes Neuronales**

De Enrique Cabello Pardos – Universidad Politécnica de Madrid - Departamento de Tecnología Fotónica - Facultad de Informática 2004.

Es un trabajo bastante completo donde se puede apreciar diferentes técnicas de tratamiento de imágenes para mejorar la calidad de los patrones que se intenta reconocer con RNA. En esta Tesis se han estudiado técnicas basadas en imágenes bidimensionales y se ha realizado un estudio inicial basado en un modelo tridimensional del rostro. En dos dimensiones, se han propuesto dos técnicas de reducción de información, basadas en la utilización de análisis de componentes principales y el empleo de imágenes de baja resolución. También se ha desarrollado un modelo de rostro de tres dimensiones comprobándose que es posible el ajuste a una nube de puntos poco densa, concluyendo que estos datos permiten obtener resultados más robustos.

En esta tesis también se explica la implementación de un sistema de verificación facial, que toma como datos de entrada una imagen y un número de identificaciones personales (PIN), asignado a cada sujeto de la base de datos; el sistema informa si la imagen y el PIN pertenecen al mismo sujeto, precisando el nivel de confianza de dicha afirmación.

g) **Tesis de Maestría - Técnicas para mejorar el Reconocimiento de Voz en Presencia de Habla Fuera del Vocabulario**

De Heriberto Cuayáhuatl Portilla - Fundación Universidad de las Américas de Puebla - Escuela de Ingeniería - Departamento de Sistemas Computacionales.

Este trabajo perfecciona los anteriores en su rubro ya que permite reconocer la voz en presencia de elementos distorsionantes como ruidos o voces titubeantes, palabras fuera del vocabulario, etc.

En primer lugar se explica el proceso del reconocimiento de voz en el contexto actual; luego explica detalladamente los componentes del Speech Works.

Luego se describe la estructura experimental para el reconocimiento de voz en presencia del habla fuera el vocabulario y se explica la preparación del cuerpo de entrenamiento y la prueba de reconocimiento.

Finalmente se evalúan y perfeccionan los resultados de los experimentos. La tesis concluye con una discusión de los experimentos realizados.

h) **PAPER - Aplicaciones de las Redes Neuronales en el Ámbito de las Adicciones.**

El autor Palmer Poul, de la Universidad de las Islas Baleares (UIB), departamento de Psicología, muestra estructuras matemáticas tipo matrices para la representación del conocimiento y así mismo establece indicadores para la medición de las adicciones.

CAPÍTULO II

MARCO TEÓRICO

2.1 REDES NEURONALES ARTIFICIALES (RNA)

2.1.1 Definición de Redes Neuronales Artificiales

Una RNA [Anderson95] es un modelo computacional inspirado en redes neuronales biológicas que puede ser considerada como un sistema de procesamiento de información, es una estructura distribuida, de procesamiento paralelo, formada de neuronas artificiales (llamados también elementos de procesamiento), interconectados por un gran número de conexiones (sinapsis), los cuales son usados para almacenar conocimiento que está disponible para poder ser usado, intenta emular las funciones computacionales elementales de la red nerviosa del cerebro humano, en base a la interconexión de multitud de elementos de procesamiento, cada uno de los cuales presenta un comportamiento completamente local.

Según [Hilera95] una RNA es un modelo matemático constituido por un conjunto de unidades de procesamiento llamados Neuronas, células o nodos, interconectados entre sí por varias ligaduras de comunicación directa llamadas conexiones, con la finalidad de recibir señales de entrada, procesarlas y emitir señales de salida.

Cada conexión está asociada a un peso, que representa la información utilizada por las neuronas para resolver un problema específico.

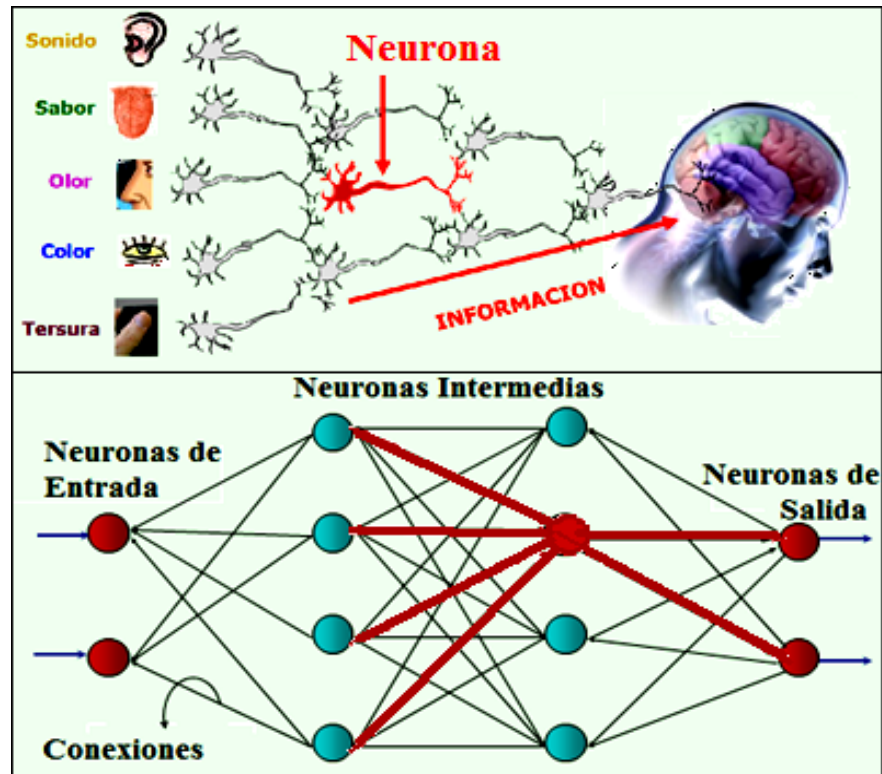


Figura 2.1: Comparación de una Red Neuronal Biológica y una RNA

Cada uno de estos procesadores o neuronas suma las entradas ponderadas y su resultado pasa a través de una función no lineal conocida como función de activación. Las entradas a una neurona pueden provenir de fuentes externas o de otras neuronas en la red. Así mismo la salida de una neurona es enviada a otras neuronas o al entorno.

El conocimiento en una RNA está distribuido a lo largo de todo el sistema, debido a esto, se utilizan muchas interconexiones para obtener la solución de un problema en particular.

2.1.2 Elementos Básicos de una Neurona

Según [Freeman91] los elementos básicos de una Neurona Artificial son:




Figura 2.2: Representación de una Neurona.

- Conjunto de entradas o vector de entradas \mathbf{x} , de n componentes.
- Conjunto de pesos sinápticos w_{ij} , representan la interacción entre la neurona pre sináptica j y la post sináptica i .
- Regla de propagación $d(w_{ij}, x_j(t))$, proporciona el potencial post sináptico, $h_i(t)$.
- Función de activación $a_i(t)=f(a_i(t-1), h_i(t))$: proporciona el estado de activación de la neurona en función del estado anterior y del valor post sináptico.
- Función de salida $F_i(t)$: proporciona la salida $y_i(t)$, en función del estado de activación.

Las señales de entrada y salida pueden ser señales binarias (0,1 – neuronas de McCulloch y Pitts), bipolares (-1,1), números enteros o continuos, variables borrosas, etc.

La regla de propagación suele ser una suma ponderada del producto escalar del vector de entrada y el vector de pesos:

$$h_i(t) = \sum w_{ij} \cdot x_j$$

También se usa a menudo la distancia euclidiana entre ambos vectores:

$$h_i(t) = \sum (x_j \cdot w_{ji})^2$$

Existen otro tipo de reglas menos conocidas como la distancia de Voronoi, de Mahalanobis, etc.

La función de activación no suele tener en cuenta el estado anterior de la neurona, sino sólo el potencial $h_i(t)$. Suele ser una función determinista y casi siempre continua y monótona creciente. Las más comunes son la función signo (+1 si $h_i(t) > 0$, -1 en caso contrario), la función semilineal y las funciones sigmoides:




Figura 2.3: Representación de los Tipos de Funciones de Activación.

La función de salida suele ser la identidad. En algunos casos es un valor umbral (la neurona no se activa hasta que su estado supera un determinado valor).

Para el aprendizaje de la RNA se combinan modelos matemáticos de las células nerviosas y modelos de arquitecturas que describen las interconexiones que existen entre estas células. Modelo de funcionamiento de una neurona real:

Concebida como un sistema de entrada/salida:

$$y = f\left(\sum_{i=1}^n \omega_i x_i - \theta\right)$$

Actividad interna de la célula se define como:

$$a = \sum_{i=1}^n \omega_i x_i - \theta$$

De esta forma la variable 'y' de salida es la intensidad de la señal que emite la célula, que es el valor que toma en la actividad la función de transferencia 'f'. El umbral 'q' se interpreta como un peso sináptico 'w0' que se aplica a una entrada que vale permanentemente -1.



Figura 2.4: Funciones de Transferencia de una Neurona.

Las neuronas de la red se agrupan en capas, recibiendo la misma información que procesan de manera independiente.

2.1.3 Elementos de una Red Neuronal Artificial

Los elementos básicos de una RNA [Martin07] son los siguientes:

- Neuronas de entrada (capa de entrada).
- Neuronas de salida (capa de salida).
- Neuronas intermedias (capas ocultas)
- Conjunto de conexiones o pesos sinápticos entre las neuronas




Figura 2.5: Elementos de una Red Neuronal Artificial.

2.1.4 Principales Características de las Redes Neuronales Artificiales.

Según [Hilera95] las principales características de las RNA son, como apreciaremos muy semejantes a las de las Redes Neuronales Biológicas, entre las principales podemos mencionar las siguientes:

- Aprenden a través de ejemplos.
- Inferencia estadística.
- Adaptabilidad.
- Dilema plasticidades y estabilidad.
- Capacidades de generalización.
- Tolerante a fallas.
- Rápida implantación.

2.2 CLASIFICACIÓN DE LAS RNA

Las RNA se pueden clasificar según su arquitectura, el tipo de aprendizaje y según sus aplicaciones [Charytoniuk00].

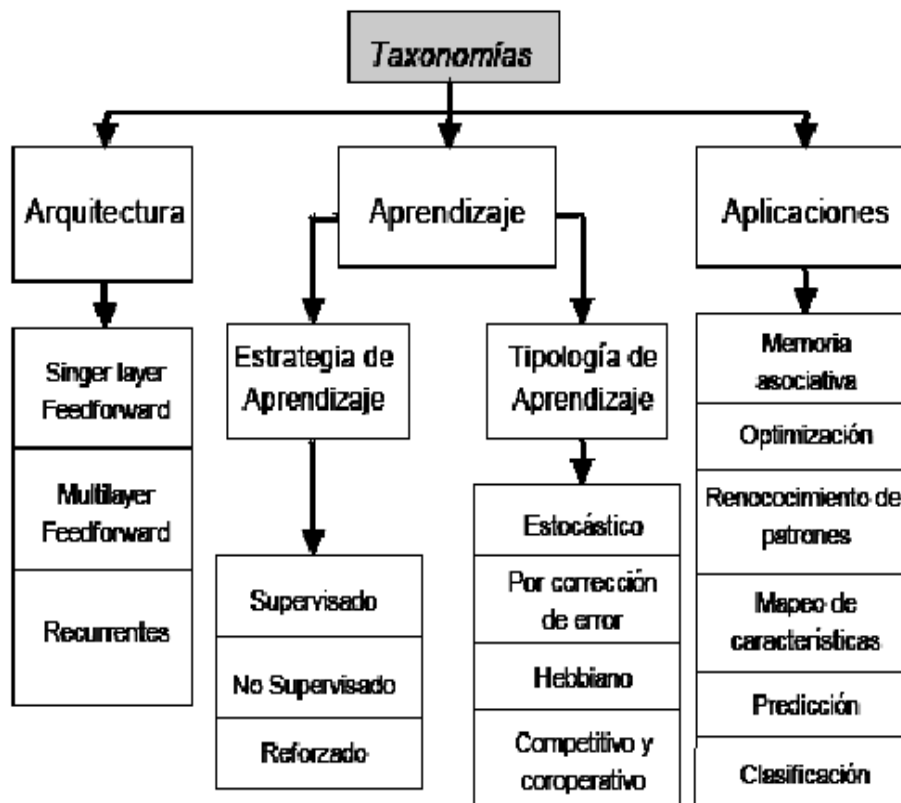


Figura 2.6: Taxonomía de las Redes Neuronales.

2.2.1 Según su Arquitectura.

Las neuronas de una RNA están distribuidas en niveles o capas que están unidas entre sí por conexiones llamadas sinapsis; dependiendo del sentido de sus conexiones pueden ser recurrentes y no recurrentes².

2.2.1.1 Con Conexiones hacia Adelante (No Recurrentes o Feedforward)

Son aquellas cuyas conexiones son hacia adelante y unidireccionales. Según el número de capas que posean pueden ser:

² Ver un cuadro de clasificación más completo en el Anexo B.

a. Redes Neuronales Monocapa.

Sólo tienen una capa de neuronas que proyectan las entradas a una capa de neuronas de salida, donde se realizan diferentes cálculos.




Figura 2.7: RNA con Conexiones hacia Adelante Mono-Capa.

Entre las RNA más conocidas con esta arquitectura se encuentran: el Monolayer Perceptron y el ADALINE.

b. Redes Neuronales Multicapa.

Es una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la salida.




Figura 2.8: RNA con Conexiones hacia Adelante Multicapa.

Entre las RNA más conocidas con esta arquitectura se encuentran el Multilayer Perceptron y el MADALINE.

2.2.1.2 Con Conexiones hacia Atrás (Recurrentes o Feedback)

Se caracterizan por la existencia conexiones de retorno entre neuronas de una determinada capa con otras de capas anteriores, conexiones entre neuronas una misma capa o conexiones de una neurona consigo misma.




Figura 2.9: RNA con Conexiones hacia Atrás.

Entre las más conocidas con esta arquitectura se encuentran las SOM de Kohonen, Hopfield y las redes ART.

2.2.2 Según Su Aprendizaje

2.2.2.1 Aprendizaje Supervisado (con Maestro)

Una RNA realiza un aprendizaje supervisado cuando tiene un supervisor en el entrenamiento de la red, significa que existe un parámetro de referencia ya conocido (maestro), el cual es comparado con las salidas de la red, el aprendizaje supervisado se caracteriza por un entrenamiento controlado por una agente externo que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor comprueba la salida de la red y en el caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada. **Un aprendizaje supervisado requiere disponer de un conjunto de patrones de los cuales se conoce su clase cierta.**

A este conjunto se le denomina conjunto de entrenamiento. Este tipo de entrenamiento se denomina entrenamiento supervisado y los clasificadores así obtenidos son clasificadores supervisados.




Figura 2.10: Aprendizaje Supervisado de una RNA.

2.2.2.2 Aprendizaje No Supervisado (Sin Maestro)

Estos tipos de redes no tienen una referencia de comparación por lo cual contemplan la autoorganización y la autoasociación, como procesos de obtención de la salida de la red. Se caracteriza por que la salida no requiere ser contrastada con algo específico ya conocido (maestro).

El aprendizaje no supervisado es conocido también como auto supervisado no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas, por ello, suele decirse que estas redes son capaces de auto organizarse.

2.2.3 Según su Aplicación.

- Redes de Reconocimiento de Patrones, son del tipo no recurrente y con aprendizaje supervisado.
- Redes de Clasificación, hacen uso del aprendizaje no supervisado para obtener características de clasificación a base de las entradas del problema.
- Redes de Predicción, tienen como objetivo modelar una función no lineal.

- Redes de Memoria Asociativa. Aprender es el proceso donde se forman asociaciones entre patrones relacionados. Asociamos patrones con la misma modalidad sensitiva (imagen visual con otra imagen) o con tipos diferentes (un olor con una imagen).
- Redes de Mapeo de Características.
- Redes de optimización.

2.3 PARÁMETROS DE UNA RED NEURONAL

Según [Pino01] se consideran ciertos parámetros para la creación de una RNA. A continuación, se mencionan las más importantes:

2.3.1 Parámetros Topológicos

N: Número de neuronas en la capa de entrada.

Y: Número de neuronas en la capa de salida.

O: Número de neuronas en la capa oculta.

Wij: Peso sináptico de la neurona i hacia la neurona j.

2.3.2 Algoritmos de Aprendizaje

Los algoritmos más comunes utilizados en el entrenamiento de las RNA son el Backpropagation y todas sus variantes, el algoritmo presenta dos fases que son las siguientes:

- Fase de Aprendizaje o Entrenamiento
En esta fase se requieren los datos de entrada y salida, el algoritmo de aprendizaje se encarga de generar una función que los vincule.
- Fase de Recuerdo o Reconocimiento
En esta fase se requieren los datos de entrada y la RNA utilizando la función generada en la fase de aprendizaje genera los datos de salida.

2.4 RNA TIPO PERCEPTRÓN MULTICAPA

Según [Anderson95], el Perceptrón intenta modelar el comportamiento de la neurona biológica, trabaja con funciones de activación, el cuerpo de la neurona es representado como un sumador lineal de estímulos Z_j , seguida por una función no lineal $f(Z_j)$ que es la función de activación, esta utiliza la suma de estímulos para determinar la salida de la neurona. En el Perceptrón cada entrada es multiplicada por un factor de peso W correspondiente, los resultados son sumados y luego evaluados contra el valor de umbral θ , si el valor es mayor al máximo el Perceptrón se activa.

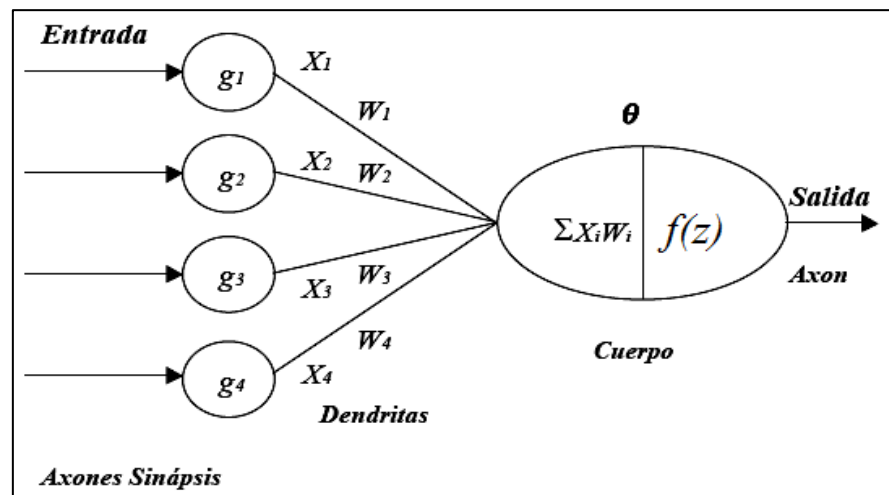


Figura 2.11: Modelo de un Perceptrón.

La primera capa actúa como un grupo de sensores que detectan una señal específica con la importancia correspondiente. La segunda capa toma salidas de los detectores y clasifica el patrón de entrada dado. El aprendizaje empieza ajustando la fuerza en las conexiones (pesos W_i) y el valor de umbral θ . La función g_i es fija y esta predeterminada.

El entrenamiento de un Perceptrón se hace utilizando una función de aprendizaje. Si la respuesta dada por el Perceptrón es incorrecta, se modifican todos los pesos de las conexiones de acuerdo a la función.

$$\Delta w_i = \eta t_i x_i$$

Donde η es la ratio de aprendizaje, t_i es la salida deseada y x es la entrada del Perceptrón. La arquitectura típica de una RNA Perceptrón Multicapa está constituida por varias capas de nodos con interconexión completa entre ellos. El caso más sencillo en este tipo de red consiste en sólo 2 capas de neuronas, las de entrada y las de salida. De esta manera podemos obtener un modelo adecuado para problemas lineales del tipo de la regresión lineal múltiple.




Figura 2.12: Modelo de un Perceptrón Multicapa.

En este tipo de red, una neurona recibe distintas entradas y activa una función de red (o regla de propagación) con unos pesos de entrada asociados. La computación de estos pesos se sigue de la aplicación de la función de activación que determina el nivel de activación de salida de la neurona.

2.5 ALGORITMO BACKPROPAGATION

2.5.1 Descripción

Conocido también como Retropropagación o propagación hacia atrás [Flores06], la primera descripción fue dada por Werbos en 1974, es un algoritmo de aprendizaje supervisado que se usa para entrenar RNA de arquitectura multicapa y con conexiones hacia adelante. El algoritmo consiste en minimizar un error (comúnmente cuadrático) por medio de gradiente descendiente, por lo que la parte esencial del algoritmo es el cálculo de las derivadas parciales de dicho error con respecto a los parámetros de la RNA.

2.5.2 Presentación del Algoritmo Backpropagation

Según [Swingler96] el algoritmo Backpropagation consta de los siguientes pasos

Inicialización:

1. Construcción de la red.
2. Inicialización aleatoria de pesos y umbrales $(-0.5, 0.5)$.
3. Criterio de terminación (número máximo de iteraciones,...).
4. Contador de iteraciones $n=0$.

Hacia Adelante

5. Seleccionamos el primer par de entrenamiento.
6. Calcular la salida de la red para cada patrón de entrada.




Figura 2.13: Backpropagation hacia Adelante.

7. Calcular el error total cometido (SSE).
8. Si la condición de terminación se satisface, parar.

Hacia Atrás

9. Incrementar el contador $n=n+1$.




Figura 2.14: Backpropagation hacia Adelante.

10. Propaga los errores hacia la capa de entrada, ajustando los pesos de las capas ocultas de forma que se minimice el error.

- Para cada neurona de salida calcular

$$\delta_k = (o_k - y_k) f'(net_k) \text{ donde } net_j = \sum_i w_{ij} x_i + b_j$$

- Para cada unidad oculta calcular

$$\delta_j = f'(net_j) \sum_k \delta_k w_{jk}$$

- Actualizar los pesos

$$\Delta w_{ij}(n+1) = \eta \delta_j o_i + \alpha \Delta w_{ij}(n)$$

11. Repetimos desde el paso 5 para cada par de entrenamiento hasta que el error para todos los conjuntos de entrenamiento sea aceptable.

2.5.3 Principales Problemas del Backpropagation ³

Los principales problemas que suelen presentarse son:

- Tiempo de entrenamiento no acotado.
- La línea de máxima pendiente no es siempre la ruta más directa hacia el mínimo de la función error.
- Puede converger a un mínimo local.
- Si la pendiente es escasa, el entrenamiento es muy lento.
- Si la pendiente es muy alta, el punto de convergencia puede ser ignorado.
- Parálisis de la red - los pesos toman valores muy grandes y la red no cambia.
- Mínimos locales - la superficie de error está llena de valles y picos. Es difícil localizar el mínimo global de energía, y se suele caer en mínimos locales.
- Dificultad en elegir la arquitectura de la red (número de capas, número de unidades en cada capa, ...), los parámetros de aprendizaje (alpha, momento, error aceptable, ...)

³ Universitat Jaume I - Proyectos Inteligentes - E67, 2006. Aplicación de Descriptores de Fourier y Redes Neuronales Artificiales para el Reconocimiento de Formas, 2006.

2.5.4 Tasa de Aprendizaje

- El algoritmo requiere que las modificaciones a los pesos de las conexiones sean infinitésimos.
- A efectos prácticos, valores finitos son suficientes para obtener la convergencia.
- α indica cuánto cambian los pesos, si es muy pequeño, la velocidad de aprendizaje es muy lenta. Si α es grande, aparecen efectos oscilatorios.

2.5.5 Término de Inercia (Momentum)

- Inercia = tendencia de un objeto a continuar a la misma velocidad si no está sujeto a ninguna fuerza (similar a una bola rodando).
- Permite superar zonas de poco gradiente y pequeños mínimos locales.
- Se cambia la fórmula de cálculo de pesos.

$$W(t) = W(t-1) + \Delta W(t) \quad /* \text{sin inercia} */$$

$$W(t) = W(t-1) + \Delta W(t) + \text{momentum} * \Delta W(t-1)$$

2.5.6 Factores que Influyen en el Rendimiento del Aprendizaje de la Red

[Duda01] nos menciona los siguientes problemas:

- Efecto del número de muestras de aprendizaje.




Figura 2.15: Efecto del Número de Muestras de Aprendizaje.

- Efecto del número de unidades ocultas.




Figura 2.16: Efecto del Número de Unidades Ocultas.

- Efecto del número de iteraciones.




Figura 2.17: Efecto del Número de Iteraciones.

- Efectos sobre-entrenamiento

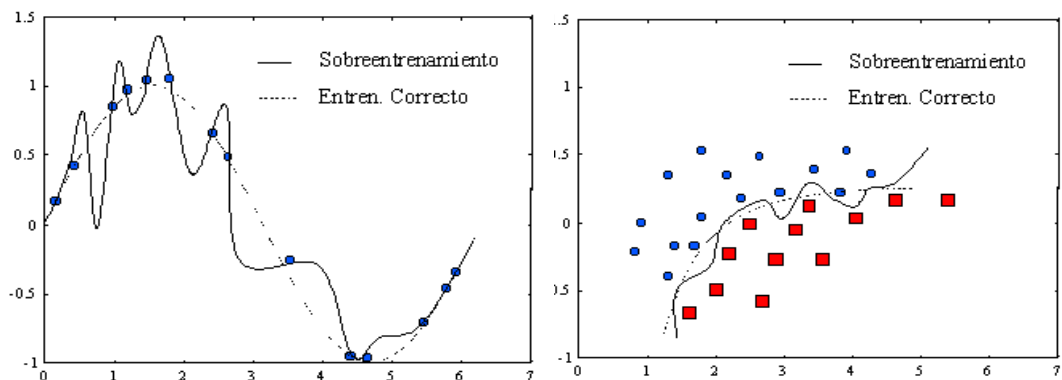


Figura 2.18: Efecto de Sobre-Entrenamiento.

2.6 RECONOCIMIENTO DE PATRONES

2.6.1 Definición.

Según [Bishop96] el reconocimiento de patrones llamado también lectura de patrones, identificación de figuras y reconocimiento de formas consiste en el reconocimiento de patrones de señales. Los patrones se obtienen a partir de los procesos de segmentación, extracción de características y descripción dónde cada objeto queda representado por una colección de descriptores. El sistema de reconocimiento debe asignar a cada objeto su categoría o clase.

Para poder reconocer los patrones se siguen los siguientes procesos:

| Adquisición de datos | Extracción de de características | Toma de decisiones |
|-------------------------|-------------------------------------|-----------------------|
|-------------------------|-------------------------------------|-----------------------|

El punto esencial del reconocimiento de patrones es la clasificación, se quiere clasificar una señal dependiendo de sus características, por ejemplo se puede clasificar imágenes digitales de letras en las clases «A» a «Z» dependiendo de sus píxeles o se puede clasificar ruidos de cantos de los pájaros en clases de órdenes aviares dependiendo de las frecuencias.

2.6.2 Sistema Básico de Reconocimiento de Patrones

El objetivo de un sistema completo de reconocimiento de patrones [Duda01], es asignar un patrón a la clase a la que pertenece (lo más automáticamente posible). Un sistema debe incluir un sensor que recoja fielmente los elementos del universo a ser clasificado, un mecanismo de extracción de características cuyo propósito es extraer la información útil, eliminando la información redundante e **irrelevante**, y finalmente una etapa de toma de decisiones en la cual se asigna a la categoría apropiada los patrones de clase desconocida a priori.




Figura 2.19: Sistema Básico de Reconocimiento de Patrones.

2.6.2.1 Sensor

El sensor es el dispositivo encargado de la adquisición de datos. Ha de ser capaz de transformar magnitudes físicas o químicas, llamadas variables de instrumentación. Las variables de instrumentación dependen del tipo de sensor y pueden ser por ejemplo: temperatura, intensidad lumínica, distancia, aceleración, inclinación, desplazamiento, presión, fuerza, torsión, humedad, etc.

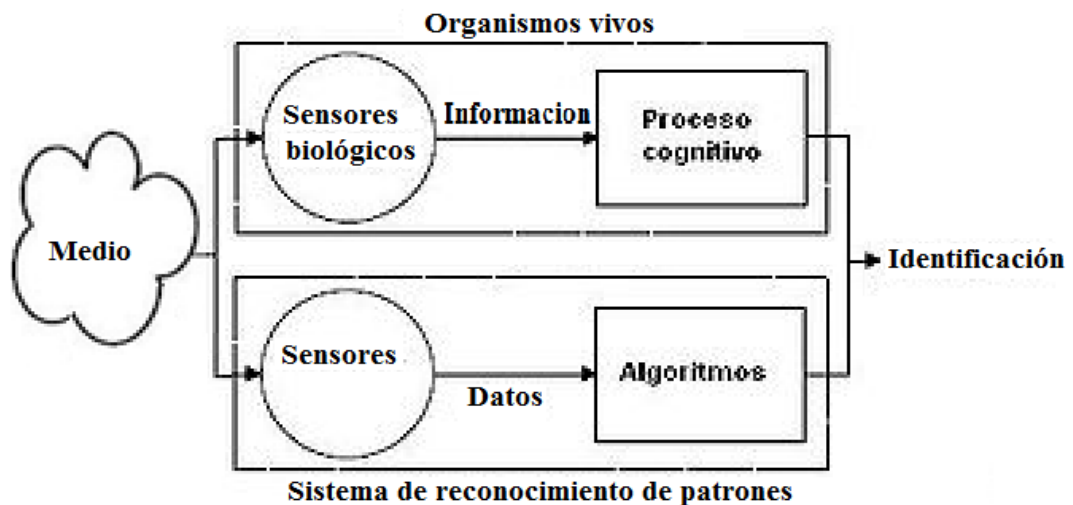


Figura 2.20: Los sensores en el Proceso de Identificación.

2.6.2.2 Extracción de Características

Es el proceso de generar características que puedan ser usadas en el proceso de clasificación de los datos. En ocasiones viene precedido por un preprocesador de la señal, necesario para corregir posibles deficiencias en los datos debido a errores del sensor, o bien para preparar los datos de cara a posteriores procesos en las etapas de extracción de características o clasificación.

Las características elementales están explícitamente presentes en los datos adquiridos y pueden ser pasados directamente a la etapa de clasificación. Las características de alto orden son derivadas de las elementales y son generadas por manipulaciones o transformaciones en los datos.

2.6.2.3 Selección de Variables

Consiste en seleccionar cuál es el tipo de características o rasgos más adecuados para describir los objetos. Para ello, se deben localizar los rasgos que inciden en el problema de manera determinante.

Esta etapa también puede ser diseñada dentro de la clasificación.

a) Objetivos:

- Decidir qué características representan mejor a cierto tipo de objetos
- Seleccionar características relevantes, a partir del conjunto total de características que describen a los objetos para mejorar la clasificación o aumentar la velocidad de procesamiento.

b) Estrategias de Selección de Variables:

- **wrapper:** la selección de características se hace usando información del mecanismo de clasificación.
- **filter:** la selección se hace con un criterio independiente del clasificador.

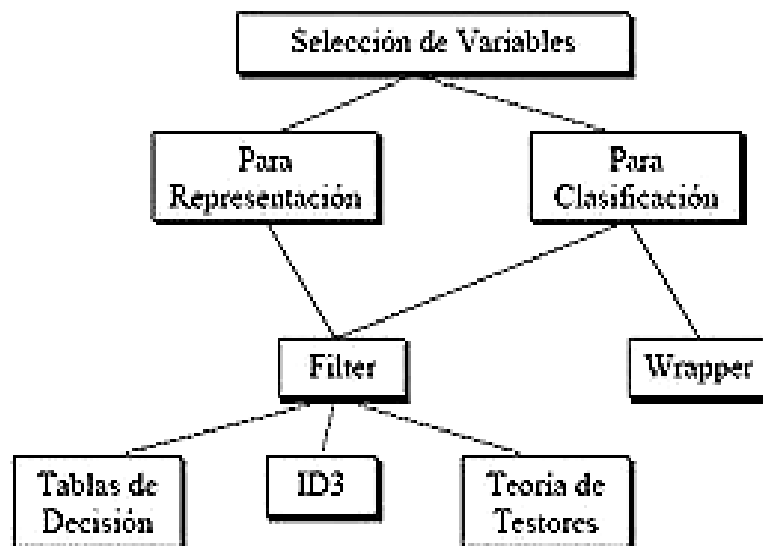


Figura 2.21: Estrategias de Selección de Variables.

2.6.2.4 Clasificación

a) Clasificación Supervisada

Se basa en la disponibilidad de áreas de entrenamiento, se trata de áreas de las que se conoce a priori la clase a la que pertenecen y que servirán para generar una signature espectral característica de cada una de las clases. Se denominan clases informacionales en contraposición a las clases espectrales que genera la clasificación no supervisada.

Algunos métodos de la clasificación supervisada:

- Funciones discriminantes.
- Vecino más cercano.
- Redes neuronales artificiales.

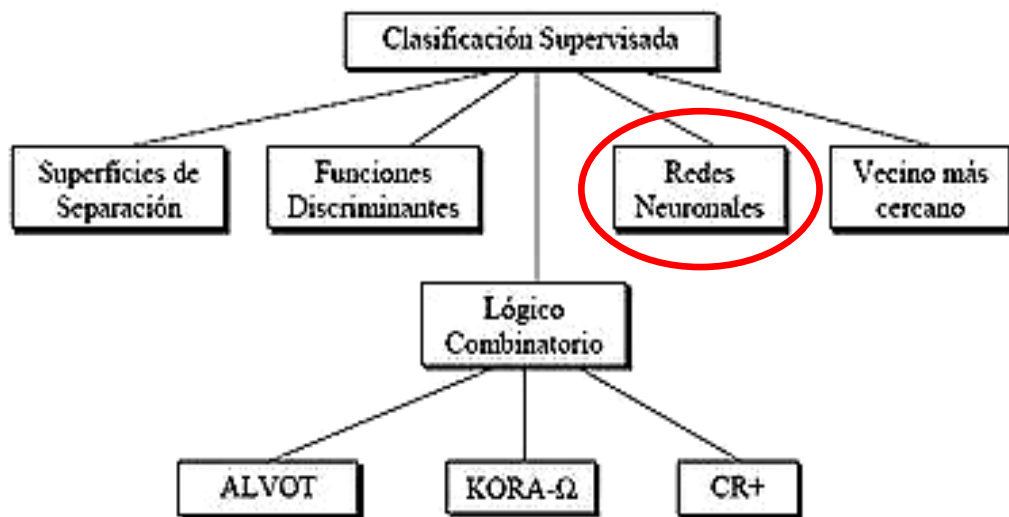


Figura 2.22: Métodos de Clasificación de Variables

b) Clasificación No Supervisada:

Se utilizan algoritmos de clasificación automática multivariante en los que los individuos más próximos se van agrupando formando clases.

- **Agrupamiento de Clases Restringida:** el número de clases en la que se estructurará la muestra está previamente definido.
- **Agrupamiento de Clases Libre:** el número de clases en la que se estructurará la muestra depende exclusivamente de los datos.

2.7 EXPORTACIÓN

2.7.1 Concepto y Tipos de Exportación

Según Roberto Concha, Director de Icecomex [W-Concha07], la exportación es la salida de bienes y servicios del territorio nacional o de una zona franca cumpliendo todos los requisitos de la ley en uso por los países involucrados y que produce como contrapartida un ingreso de divisas.

Según la transformación de los productos, las exportaciones se clasifican en:

a) Exportaciones Tradicionales

Están constituidas por bienes que no sufren una transformación importante de su esencia durante su proceso productivo. Por ejemplo, la exportación del petróleo es netamente tradicional.

b) Exportaciones no Tradicionales:

Están constituidas por productos nuevos en el ámbito exportable, que presentan un comportamiento muy dinámico; son aquellas que cambian su importancia en la economía por su crecimiento como producto de venta internacional; además, por lo general, los bienes no tradicionales llevan un alto valor agregado en su proceso productivo, como por ejemplo los cigarros, bebidas alcohólicas, automóviles, etc.

2.7.2 Balanza Comercial

Se define como la diferencia que existe entre el total de las exportaciones menos el total de las importaciones que se llevan a cabo en el país durante un período [W-Concha07].

$$\text{Balanza Comercial} = \text{Exportaciones} - \text{Importaciones}$$

Esta diferencia podría ser positiva (lo cual se denomina superávit comercial) o negativa (lo cual se denomina déficit comercial)

2.7.3 Terminologías del Comercio Internacional

Según [W-Kuyeng07], los términos más usados del comercio internacional son:




Figura 2.23: Terminologías del Comercio Internacional

EXF: (Ex-Factory) El vendedor cumple su obligación de entrega al poner la mercadería en su fábrica, taller, etc. a disposición del comprador. El comprador soporta todos los gastos y riesgos de retirar la mercadería desde el domicilio del vendedor hasta su destino final.

FAS: (Free Alongside Ship) Libre al costado del buque. El precio de la mercadería se entiende puesta al costado del navío en el puerto convenido.

FOB: (Free on Board) Libre a bordo. La mercadería es puesta a bordo del barco con todos los gastos, derechos y riesgos a cargo del vendedor hasta que la mercadería haya pasado la borda del barco, con el flete excluido.

CFR: (Cost & Freight) Costo y Flete. El precio comprende la mercadería puesta en puerto de destino, con flete pagado pero seguro no cubierto.

CIF: (Cost, Insurance & Freight) Costo, Seguro y Flete. El precio comprende la mercadería puesta en puerto de destino, con flete y seguro pagado.

DDU: (Delivered Duty Unpaid) Entregada Derechos No Pagados. El vendedor cumple con su obligación cuando pone la mercadería a disposición del comprador en el lugar convenido en el país de importación.

DDP: (Delivered Duty Paid). Entregada Derechos Pagados. El vendedor asume las mismas obligaciones que en D.D.U. más los derechos, impuestos y cargas necesarias para llevar la mercadería hasta el lugar convenido.

2.7.4 Codex Alimentarius

Según el European Food Information Council [W-Eufic10] (Consejo Europeo de Información sobre la Alimentación) el CODEX ALIMENTARIUS es el código alimentario que contiene normas generales y específicas relativas a la seguridad alimentaria, que han sido formuladas con el objetivo de proteger la salud de los consumidores y de garantizar unas prácticas equitativas en el comercio de los productos alimentarios.

El Codex Alimentarius fue creado de forma conjunta en los años 60 por dos organizaciones de las Naciones Unidas: la Organización para la Agricultura y la Alimentación (Food and Agriculture Organisation, FAO) y la Organización Mundial de la Salud (OMS). Su propósito era servir como pauta y fomentar la elaboración y el establecimiento de definiciones y requisitos para los alimentos a fin de contribuir a su armonización y de este modo facilitar el comercio internacional. La mayor parte de la población mundial vive en los 166 países que son miembros del Codex Alimentarius. Estos países participan en la elaboración de las normas y a menudo en su aplicación a nivel nacional y regional.

Cuando procede, la Organización Mundial del Comercio recurre a las normas del Codex para resolver conflictos comerciales relativos a productos alimentarios. Las normas del Codex suelen servir como punto de partida para las legislaciones y las normativas nacionales y regionales.

Básicamente, la influencia del Codex Alimentarius se extiende a todos los continentes, y su contribución a la protección de la salud pública y las prácticas equitativas en la industria alimentaria es extremadamente valiosa.

El Codex Alimentarius abarca miles de normas, que pueden ser normas generales aplicables a todos los alimentos, o normas específicas para ciertos alimentos o productos. Las normas generales comprenden las relativas a la higiene, el etiquetado, los residuos de pesticidas y medicamentos usados en veterinaria, los sistemas de inspección y certificación de las importaciones y

exportaciones, los métodos de análisis y muestreo, los aditivos alimentarios, los contaminantes, así como la nutrición y los alimentos para usos dietéticos especiales.

¿Cómo se elaboran las normas? El Codex Alimentarius está dirigido por la Comisión del Codex Alimentarius, que es un organismo intergubernamental en el que todos los países miembros tienen derecho de voto. Varios comités de especialistas se encargan de redactar las normas que, posteriormente, aprobará la Comisión del Codex.

Una norma ve la luz cuando un gobierno nacional o un comité de la Comisión del Codex, propone la creación de una norma relativa a un tema o producto alimentario en particular. Si la Comisión del Codex (o su Comité Ejecutivo) decide que es necesario elaborar una norma, la Secretaría de la Comisión del Codex redactará un anteproyecto de norma y lo someterá a los gobiernos de los países miembros para su examen.

2.8 LA EXPORTACIÓN EN EL PERÚ

Según Juan Kuyeng Ruiz, Gerente Técnico de “Exporta Fácil” de PROMPERU [W-Kuyeng07], la exportación es un régimen aduanero aplicable a las mercancías en libre comercialización que salen del territorio aduanero, para uso o consumo definitivo en el exterior las cuales no están afectas a ningún tributo en el mercado local, regulada por: Ley General de Aduanas. Decreto Legislativo 951 - Decreto Supremo N° 011-2005-EF y su reglamento.

2.8.1 Evolución de la Exportación en la Última Década

Según Martín Pérez Monteverde, Ministro de Comercio Exterior y Turismo [W-Pérez10], durante la última década, la evolución del crecimiento de las exportaciones en el Perú ha alcanzado cifras importantes. Durante el período previo a la crisis (2009), las exportaciones crecieron a un ritmo acelerado convirtiéndose en una variable clave del crecimiento económico; En el 2009, la caída de los precios de los minerales y la profundización de la crisis

financiera internacional, influyeron en la exportación nacional la misma que descendió de 33,000 (2008) a 26,625 millones de dólares es decir en un 19%.



Figura 2.24: Evolución de la Exportación en la Última Década.

Al cierre del año 2009 [W-Proinversion10], los principales países destinos de las exportaciones nacionales fueron EE. UU (17.1%), China (15.2%) y Suiza (14.7%) sumando entre los tres países el 47% de la exportación nacional.




Figura 2.25: Principales Destinos de las Exportaciones Nacionales 2009.

2.8.2 Exportaciones Tradicionales y Exportaciones no Tradicionales

Las exportaciones tradicionales y no tradicionales han tenido una tendencia importantemente creciente entre el 2000 y 2009 [W-Ccpa10].




Figura 2.26: Exportaciones Tradicionales y no Tradicionales del 2000 al 2008.

2.8.3 Oportunidades para los Exportadores

En los dos últimos años el Perú ha firmado importantes tratados de libre comercio con importantes países como Estados Unidos, Canadá, Singapur, China, la Unión Europea, esto implica la oportunidad de multiplicar nuestras exportaciones, sobre todo las no tradicionales lo cual potenciará nuestra economía ya que ello implica la transformación previa de recursos naturales en productos elaborados lo que implicará el incremento de trabajo a nivel nacional. La entrada en vigencia del TLC suscrito entre Perú y China permitirá que las exportaciones peruanas de productos no tradicionales, bienes con valor agregado, se cuadrupliquen en el año 2011 [W-Mincetur10].

2.8.4 Evolución de la Exportación de Frutas

Según [W-Siisex10], las exportaciones de frutas desde el año 2005 hasta el 2009 han tenido un crecimiento sostenido casi constante de un promedio de

70 millones de dólares por año, lo que representa una buena oportunidad para aquellas empresas que intentan incursionar en este negocio.




Figura 2.27: Evolución de la Exportación de Frutas.

Entre las principales frutas frescas exportadas, considerando las estadísticas del año 2009, se encuentra la uva con un total de 135 millones de dólares, el mango con 70 millones de dólares y la palta con 61 millones de dólares.

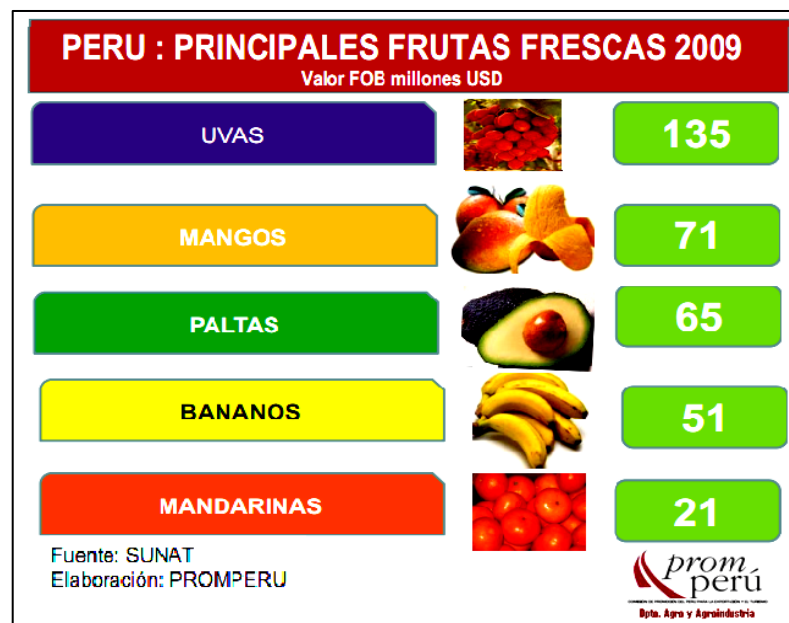


Figura 2.28: Principales Frutas Frescas Exportadas en el 2009.

2.9 EXPORTACION DEL MANGO EN EL PERU

2.9.1 Tipos y Características de los Mangos Exportables

Según [W-Mincetur10], los tipos y las características de los mangos de exportación son los siguientes:

| TIPO | TAMAÑO | COLOR | FORMA | SABOR | COSECHA |
|--------------|------------------------------|---|--|--|----------------|
| Kent | Grande (500 a 800 g) | Amarillo anaranjado con chapa rojiza a la madurez | Ovalada orbicular, | Agradable, jugoso de poca fibrosidad y de alto contenido de azúcares | Semi-tardía |
| Haden | Medio a grande (380 - 700 g) | Rojo-amarillo, con chapa rojiza | Ovalada | Agradable, de pulpa firme | Media estación |
| Tommy | Grande (600 g) | Rojo intenso | Oblonga, oval, resistente a daños mecánicos y con mayor periodo de conservación, | No muy agradable | Tardía |

Tabla 2.1: Tipos y Características de los Mangos Exportables.

2.9.2 Cadena de Valor Agregado del Mango

El mango es consumido principalmente en estado fresco [W-Mincetur10], aunque también se usa para elaborar diversas presentaciones agroindustriales.

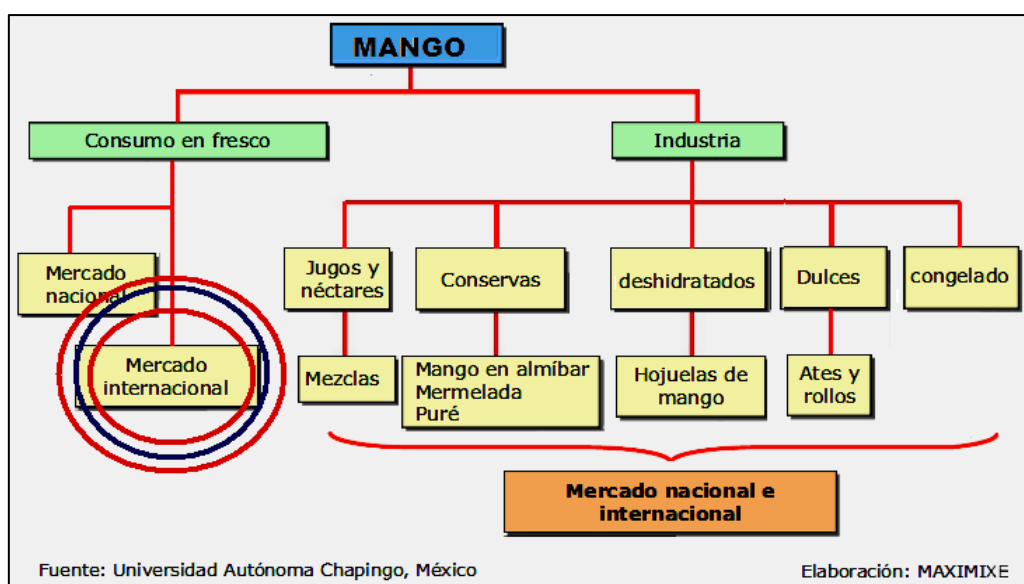


Figura 2.29: Cadena de Valor Agregado del Mango.

2.9.3 Principales Países Importadores de Mangos Frescos

Los principales países importadores de mangos frescos son EEUU con un 32% de la exportación mundial y Hong Kong con un 14% [W-Mincetur10].




Figura 2.30: Principales Países Importadores de Mangos Frescos.

2.9.4 Principales Destinos de Mango Fresco Peruano

Entre los principales destinos de mango fresco peruano, se encuentran los países bajos con un total de 38 millones de dólares (54%) y EEUU con 20 millones de dólares (28%) de un total de 70 millones de dólares [W-Mincetur10].




Figura 2.31: Principales Destinos de Mango Fresco Peruano.

2.9.5 Evolución de la Producción y Exportación de Mangos Frescos

De acuerdo a las estadísticas del ministerio de agricultura [W-Mincetur10], las exportaciones respecto a la producción se ha venido incrementando en un 30% por año.




Figura 2.32: Evolución de la Producción y Exportación de Mangos Frescos.

2.9.6 Exportación de Mangos Frescos en Toneladas y en Dólares

El precio promedio de exportación, entre el 2003 y el 2008, ha sido \$1.4 dólares por kilogramo de mango, pero en el 2009 bajó a menos de un dólar [W-Siisex10].




Figura 2.33: Evolución de la Exportación de Mangos Frescos.

2.9.7 Evolución de la Producción de Mangos por Departamentos

Se puede apreciar que del 200 al 2007 Piura ha venido creciendo a un promedio de 30 millones de toneladas al año [W-Agrobanco07].




Figura 2.34: Evolución de la Producción de Mangos por Departamentos.

2.9.8 Exportación por Tipos de Mango

En la tabla 2.1 apreciamos los tipos de mangos exportables y sus características, A continuación apreciaremos los porcentajes de exportación promedio por cada uno de ellos [W-Mincetur10].




Figura 2.35: Exportación por Tipos de Mango.

2.9.9 Costos de Exportación de Mango Fresco

El costo de exportación de mango fresco para un contenedor de 5160 cajas de 4,25 Kg alcanza los US\$ 21,9 mil, de los cuales el 62,8% representa el costo en que se incurre hasta colocar la carga en el puerto de embarque y el resto a los costos de envío al puerto de destino, suponiendo un precio de US\$ 4.5 por caja y una comisión de 10% del precio de venta para el bróker [W-Mincetur10].

| Costos de Exportación de Mango Fresco (US\$) | | | |
|---|-------------------|----------------------------|--------------|
| Rubros | Caja (4.25 Kg) | Contenedor (5160 cajas) | Part. % |
| Costo Total | 4,245 | 21 904,2 | 100,0 |
| I. Costos de Exportación hasta Puerto de Embarque | 2,665 | 13751,4 | 62,8 |
| Adquisición de fruta | 0,850 | 4386,0 | 20,0 |
| Cosecha y transporte a la empacadora | 0,304 | 1568,6 | 7,2 |
| Proceso de empaclado | 0,900 | 4644,0 | 21,2 |
| Insumo de empaque | 0,440 | 2270,4 | 10,4 |
| Agenciamiento de Aduana | 0,048 | 247,7 | 1,1 |
| Preparación de documentos de embarque y envío por courier | 0,008 | 41,3 | 0,2 |
| Seguros locales | 0,015 | 77,4 | 0,4 |
| Gastos financieros | 0,100 | 516,0 | 2,4 |
| II. Costos de Envío hasta Puerto de Destino | 1,580 | 8152,8 | 37,2 |
| Flete marítimo | 0,795 | 4102,2 | 18,7 |
| Seguro de mercadería | 0,010 | 51,6 | 0,2 |
| Gastos de destino | 0,125 | 645,0 | 2,9 |
| Gastos de almacenaje | 0,200 | 1032,0 | 4,7 |
| Comisión de venta (10% del precio de venta) | 0,450 | 2322,0 | 10,6 |
| 1/ Asumiendo un precio de venta de US\$ 4.5 por caja | | | |
| Fuente: APEM | | Elaboración: MINAG | |
| Mercado: EEUU | | | |

Tabla 2.2: Costos de Exportación de Mango Fresco.

2.9.10 Estándares Nacionales e Internacionales de los Mangos Exportables

A continuación podemos apreciar algunos estándares sobre los mangos exportables tanto internacionales [W-Onu-Codex93], especificados en las normas del CODEX STAN 184-1993 (documento completo en el Anexo C), como nacionales [W-Senasa02], especificados en la Norma Técnica Peruana NTP 011.010 2002.

a) Requisitos Mínimos

- Estar enteros.
- Estar sanos, deberán excluirse los productos afectados por podredumbre o deterioro que hagan que no sean aptos para el consumo.
- Estar prácticamente exentos de daños causados por plagas.
- Estar exentos de cualquier olor y/o sabor extraños.
- Ser de consistencia firme.
- Tener un aspecto fresco.
- Estar exentos de daños causados por bajas temperaturas.
- Estar exentos de manchas necróticas negras ó estrías.
- Estar suficientemente desarrollados y presentar un grado de madurez satisfactorio.
- Cuando tengan pedúnculo, su longitud no deberá ser superior a 1.0 cm.

El estado y condición de los mangos deberán ser tales que les permitan:

- Asegurar la continuidad del proceso de maduración hasta que alcancen el grado de madurez adecuado, de conformidad con las características peculiares de la variedad.
- Soportar el transporte y la manipulación y llegar en estado satisfactorio al lugar de destino.

b) Clasificación

Los mangos se clasifican en tres categorías, según se definen a continuación:

Categoría Extra, los mangos de esta categoría deberán ser de calidad superior y característicos de la variedad. **No deberán tener defectos**, salvo defectos superficiales muy leves siempre y cuando no afecten al aspecto general del producto, su calidad, estado de conservación y presentación en el envase.

Categoría I, los mangos de esta categoría deberán ser de buena calidad y característicos de la variedad. Podrán permitirse, sin embargo, los siguientes defectos leves, siempre y cuando no afecten al aspecto general del producto, su calidad, estado de conservación y presentación en el envase:

- **Defectos leves de forma.**
- Defectos leves de la cáscara debidos a rozaduras, manchas o quemaduras producidas por el sol.

c) Disposiciones Relativas a la Clasificación por Calibres

El calibre se determina por el peso de la fruta, según el siguiente cuadro:

| Código de calibre | Peso (en gramos) |
|-------------------|------------------|
| A | 200 - 350 |
| B | 351 - 550 |
| C | 551 - 800 |

La diferencia máxima de peso permisible entre las frutas contenidas en un mismo envase que pertenezcan a uno de los grupos de calibres mencionados anteriormente será de 75, 100 y 125 gr. respectivamente.

d) Disposiciones Relativas a las Tolerancias de Calidad

Categoría Extra, El 5%, en número o en peso, de los mangos que no satisfagan los requisitos de esta categoría pero satisfagan los de la Categoría I

2.10 PRODUCTOS

2.10.1 Definición de Productos

El producto es un conjunto de atributos que el consumidor considera que tiene un determinado bien para satisfacer sus necesidades o deseos. Según un fabricante, el producto es un conjunto de elementos físicos y químicos engranados de tal manera que le ofrece al usuario posibilidades de utilización [Bonta02].

El producto es un conjunto de atributos tangibles e intangibles que abarcan empaque, color, precio, calidad y marca, más los servicios y la reputación del vendedor; el producto puede ser un bien, un servicio, un lugar, una persona o una idea [Stanto07].

2.10.2 Control de Calidad

Calidad en la industria y en los servicios nos muestra que pasamos de una etapa donde la calidad solamente se refería al control final para separar los productos malos de los productos buenos, a una etapa de Control de Calidad en el Proceso, poniendo en práctica el lema: “La calidad no se controla, se fabrica”.

Finalmente llegamos a una Calidad de Diseño que significa no solo corregir o reducir defectos sino prevenir que estos sucedan, como se postula en el enfoque de la Calidad Total [Castellano98].

El Control de Calidad es la primera etapa en la gestión de la calidad que se basa en técnicas de inspección aplicadas a producción. Posteriormente nace el Aseguramiento de la Calidad, fase que persigue garantizar un nivel continuo de la calidad del producto o servicio proporcionado. Finalmente se llega a lo que hoy en día se conoce como Calidad Total, un sistema de gestión empresarial íntimamente relacionado con el concepto de Mejora Continua y que incluye las dos fases anteriores [García05].

2.10.3 Aseguramiento de Calidad

Consiste en tener y seguir un conjunto de acciones planificadas y sistemáticas, implantadas dentro del Sistema de Calidad de la empresa. Estas acciones deben ser demostrables para proporcionar la confianza adecuada (tanto a la propia empresa como a los clientes) de que se cumplen los requisitos del Sistema de la Calidad [Betancourt10].

2.10.4 Marco Normativo Legal

Base Legal: Decreto Supremo N° 030-2005-PRODUCE.

Contenido: Que mediante Ley N° 28312, publicada el 4 de agosto de 2004, se declaró de interés nacional el Programa Nacional "Cómprale al Perú", a cargo del Ministerio de la Producción, que el indicado programa nacional tiene por objeto promover la fabricación y compra de productos industriales manufacturados en el Perú que cumplen con estándares de calidad y disposiciones sanitarias exigibles, con la finalidad de fortalecer una oferta de productos debidamente certificados.

Base Legal: Reglamento de la ley N° 28312 - ley que crea el Programa Nacional "Cómprale al Perú".

Contenido: Establece las modalidades y requisitos de inscripción, obligaciones, infracciones, sanciones, así como las condiciones de uso del Sello de Calidad, de carácter nacional e internacional, y lemas correspondientes al Programa Nacional "Cómprale al Perú", cuya aplicación rige para personas naturales o jurídicas que forman parte del mismo.

2.11 EVALUACIÓN COMPARATIVA DE MÉTODOS DE RECONOCIMIENTO DE PATRONES

2.11.1 Criterios de Comparación

A continuación, se presenta una tabla donde se pueden apreciar los criterios

que permitirán evaluar los métodos de reconocimiento de patrones con sus respectivas puntuaciones.

| Criterio | Valores | Puntaje |
|-------------------------|----------------------------------|---------|
| Costo | Alto | 1 |
| | Moderado | 2 |
| | Bajo | 3 |
| Precisión | Variable | 1 |
| | Adecuada | 2 |
| | Alta | 3 |
| Datos requeridos | Alto | 1 |
| | Bajo | 2 |
| | Muy bajo | 3 |
| Amortiguación de ruidos | No | 0 |
| | Sí | 1 |
| Patrón de datos | Estacional | 0 |
| | Tendencial | 1 |
| | Cíclicos | 1 |
| | Estacional y tendencial | 2 |
| | Estacional y cíclico | 2 |
| | Tendencial y cíclico | 3 |
| | Estacional, tendencial y cíclico | 4 |
| Tipo de modelos | Lineal | 1 |
| | No lineal | 2 |

Tabla 2.3: Criterios de Comparación de Métodos de Reconocimiento de Patrones.

2.11.2 Cuadro Comparativo de Métodos para el Reconocimiento de Patrones

A continuación, presentamos la tabla donde se puede apreciar la ventaja comparativa valorada de cada modelo, criterio por criterio y en forma totalizada.

| Criterio/Modelo | Método cualitativos | | Promedios Móviles | | Ajuste Exponencial | | Redes Neuronales | |
|-------------------------|---------------------|---|-------------------|---|--------------------|---|------------------|----|
| Costo | Alto | 1 | Bajo | 3 | Alto | 1 | Moderado | 2 |
| Precisión | Variable | 1 | Adecuada | 2 | Adecuada | 2 | Alta | 3 |
| Datos Disponibles | Alto | 1 | Bajo | 2 | Muy bajo | 3 | Ato | 1 |
| Amortiguación de ruidos | No | 0 | No | 0 | No | 0 | Si | 1 |
| Patrón de datos | | | Estacional | 2 | Tendencial | 1 | Tendencial | 4 |
| Tipo de modelo | Lineal | 0 | Lineal | 0 | Lineal | 0 | No lineal | 1 |
| Costo | | 3 | | 9 | | 7 | | 12 |

Tabla 2.4: Cuadro Comparativo de Métodos para el Reconocimiento de Patrones.

Podemos apreciar que el modelo de RNA es el mejor en el reconocimiento de patrones.

2.12 EVALUACIÓN COMPARATIVA DE RNA EN EL RECONOCIMIENTO DE PATRONES

Después de saber que el mejor método para el reconocimiento de patrones es el uso de RNA; como existen varios modelos, pasaremos a ver qué modelo es el más adecuado.

2.12.1 Criterios de Comparación

Los primeros criterios optados forman parte del trabajo de una tesis doctoral titulada “Redes Neuronales Aplicadas al análisis de datos”

[Montaño02], la cual considera cinco elementos importantes para elegir el tipo de red a utilizar en un problema de pronóstico.

- Convergencia.
- Tasa de minimización del error.
- Complejidad de la red.
- Robustez.
- Tiempo de entrenamiento.

A continuación, se presenta una tabla donde se pueden apreciar los criterios que permitirán evaluar los métodos de reconocimiento de patrones con sus respectivas puntuaciones.

| Criterio | Valores | Puntaje |
|---------------------------------------|----------------|----------------|
| Convergencia | <i>Baja</i> | <i>2</i> |
| | <i>Alta</i> | <i>5</i> |
| Tasa de minimización del error | <i>Baja</i> | <i>2</i> |
| | <i>Alta</i> | <i>4</i> |
| Complejidad de la red | <i>Mayor</i> | <i>1</i> |
| | <i>Menor</i> | <i>3</i> |
| Robustez | <i>Menor</i> | <i>1</i> |
| | <i>Mayor</i> | <i>3</i> |
| Tiempo de Entrenamiento | <i>Alta</i> | <i>1</i> |
| | <i>Bajo</i> | <i>3</i> |

Tabla 2.5: Criterios de Comparación para Evaluación Comparativa de RNA en el Reconocimiento de Patrones.

2.12.2 Cuadro Comparativo de Modelos de RNA en el Reconocimiento de Patrones

A continuación, presentamos la tabla donde se puede apreciar la ventaja comparativa valorada de cada modelo, criterio por criterio y en forma totalizada.

| Criterio \ Modelo | Perceptrón multicapa | | Red de Elman | | RBF | | Red de Jordan | |
|-------------------------|----------------------|----|--------------|----|-------|----|---------------|----|
| Convergencia | Alta | 5 | Alta | 5 | Alta | 5 | Alta | 5 |
| Minimización del error | Alta | 4 | Alta | 4 | Alta | 4 | Alta | 4 |
| Complejidad de la red | Mayor | 3 | Menor | 1 | Mayor | 1 | Menor | 1 |
| Robustez | Menor | 3 | Mayor | 3 | Mayor | 3 | | |
| Tiempo de entrenamiento | Bajo | 1 | Alto | 1 | Bajo | 2 | Alto | 1 |
| Total | | 16 | | 14 | | 15 | | 11 |

Tabla 2.6: Cuadro Comparativo de Modelos de RNA en el Reconocimiento de Patrones.

Con estos resultados podemos concluir que lo mejor para nuestro proyecto es el uso de RNA del tipo Perceptrón multicapa.

CAPÍTULO III

METODOLOGÍA

3.1 TIPO DE LA INVESTIGACIÓN

En la presente investigación, hemos empleado tanto una investigación básica como una investigación aplicada⁴.

Hemos realizado una investigación básica para el planteamiento de una nueva metodología, óptima y muy diferente a las existentes, **para generar los patrones de entrenamiento** para reconocer imágenes utilizando RNA.

Hemos realizado una investigación aplicada para buscar una RNA que aprenda a reconocer los patrones de las formas de los mangos, **generados en la investigación básica**, y reconozca la calidad morfológica de los mangos de exportación.

⁴ Sánchez Sotomayor, Segundo, 2010, Metodología: El Curso, 1ª Edición, CEPREDIM-UNMSM, Lima- Perú.

3.2 DISEÑO DE LA INVESTIGACIÓN

La presente investigación tiene dos etapas bien diferenciadas, en la primera etapa se ha empleado un diseño no experimental y en la segunda etapa un diseño experimental.

La etapa no experimental corresponde al manejo de los valores de las formas de los mangos y su calidad exportable de los mismos, estos son tomados de la naturaleza como tales y no pueden ser manipuladas por el investigador. En esta etapa se elabora un modelo matemático para la captura del patrón morfológico de los mangos basado las imágenes de los mismos capturados mediante cámaras digitales.

Para la segunda etapa, el modelo el diseño experimental que utilizaremos es el modelo de prueba y posprueba con grupos experimentales




Figura 3.1: Modelo del Diseño Experimental.

3.3 ESTRATEGIA DE LA PRUEBA DE LA HIPÓTESIS

Para la prueba de la hipótesis, en primer lugar, seleccionaremos una muestra de mangos exportables, luego buscaremos una RNA capaz de reconocer acertadamente todos los elementos de la muestra.

Cuando se consiga la RNA bien entrenada, será sometida a la prueba de reconocer mangos exportables y no exportables, si en esta prueba logramos efectivamente tener un margen de error menor al 5 % entonces diremos que hemos alcanzado nuestro objetivo y que nuestra hipótesis ha sido demostrada.

3.4 POBLACIÓN

La población está constituida por todos los mangos que han sido seleccionados como exportables por la inspección ocular hecha por los trabajadores de la empresa Biofruit en un día de ocho horas laborales, que son aproximadamente 20,000 unidades equivalentes a 800 cajas de 25 unidades cada una; como se ha mencionado los tipos de mangos exportables son: Kent, Haden y Tommy, por lo tanto en la población se encontrarán los tres tipos de mangos.

3.5 MUESTRA PARA EL ENTRENAMIENTO DE LA RNA

3.5.1 Descripción de la Muestra

Según la figura 2.35, la exportación por tipos de mangos tienen la siguiente proporción: Kent 82%, Haden 11% y Tommy 7%, por lo tanto, estadísticamente deberíamos seleccionar una muestra que contenga los tres tipos de mangos en cifras proporcionales.

Pero, para el entrenamiento de RNA en el reconocimiento de patrones, se debe tener una muestra especialmente seleccionada, por cada de patrón que se desea reconocer, considerando que todos los elementos de cada muestra tengan diferencias considerables entre sí y al mismo tiempo representen toda la variedad posible de su población.

Por lo tanto, para resolver problemas mediante el entrenamiento de RNA el tamaño de la muestra no depende del tamaño de la población sino de cuan diferentes son entre sí los elementos que conforman dicha población.

Como el objetivo de la presente investigación es reconocer los tres tipos de mangos exportables, entonces, debemos tomar en total tres muestras independientes entre sí, una por cada tipo de mango.

Analizando las diferencias morfológicas existentes entre mangos por cada tipo de mango exportable, conjuntamente con dos expertos en el entrenamiento de RNA, determinamos que **10 unidades serían suficientes para conformar cada muestra que represente la variedad de formas** existentes de su respectiva población.

3.5.2 Selección de la Muestra

Por las razones explicadas en el numeral 3.5.1, trabajaremos con una muestra de tamaño 10 por cada tipo de mango. Por lo tanto las tres muestras fueron conformadas de la siguiente manera:

M1: 10 unidades de mango tipo Kent exportable.

M2: 10 unidades de mango tipo Haden exportable.

M3: 10 unidades de mango tipo Tommy exportable.

Para la selección de nuestra muestra hemos procedido de la siguiente manera: Pedimos que dos trabajadores de la empresa Biofruit, expertos en la selección de mangos elijan 50 unidades de la mejor calidad de cada tipo de mango, es decir 150 mangos en total.

De los 150 mangos seleccionados por los expertos, teniendo en consideración solamente los tamaños y las formas, por cada tipo de mango seleccionamos las 10 unidades más diferentes entre sí, los mismos que conformaron nuestra muestra.

Una especificación matemática de cada muestra y sus respectivos elementos sería la siguiente:

$M1 = \{K1, K2, K3, K4, \dots K10\}$; Mangos tipo Kent exportable.


$M2 = \{H1, H2, H3, H4, \dots H10\}$; Mangos tipo Haden exportable.

$M3 = \{T1, T2, T3, T4, \dots T10\}$; Mangos tipo Tommy exportable.

3.6 GENERAR LOS DATOS DE ENTRADA DE LA RNA A PARTIR DE LA MUESTRA SELECCIONADA

3.6.1 Representación Funcional entre las RNA y sus Datos de Entrada y Salida

Teóricamente, la dependencia funcional entre una RNA y sus datos de entrada y salida es la siguiente:



$$[Y1, Y2, \dots Ym] = F ([X1, X2, \dots Xn])$$

Figura 3.2: Representación Funcional entre la RNA y los Datos de Entrada y Salida.

Para nuestro caso la dependencia funcional entre de los datos de entrada y salida y la RNA buscada es la siguiente:




Figura 3.3: Dependencia Funcional entre la Forma y la Calidad del Mango.

La dependencia funcional, referida a los elementos de nuestras muestras tendría el siguiente esquema:

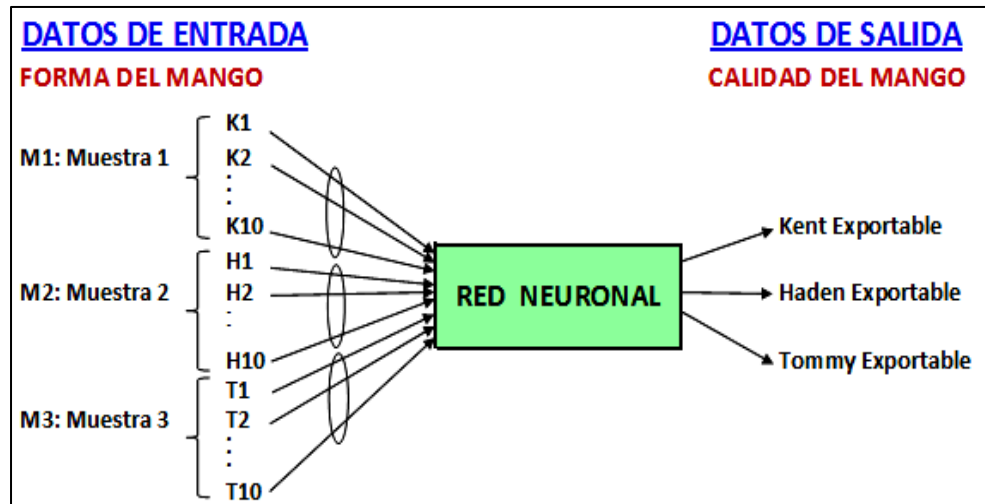


Figura 3.4: Relación entre los Elementos de la Muestra y la Calidad de los Mangos.

Como nuestro objetivo es demostrar que una RNA puede ser entrenada para reconocer los mangos de calidad, por cuestiones metodológicas solamente explicaremos el proceso en detalle para un solo tipo de mangos, ya que el proceso será idéntico en los otros casos. Para ello seleccionamos los mangos de tipo Kent ya que según la figura 2.35 representa el 82% de la población de mangos exportables. Por lo tanto la dependencia funcional de nuestra RNA y sus datos de entrada y salida será la siguiente:

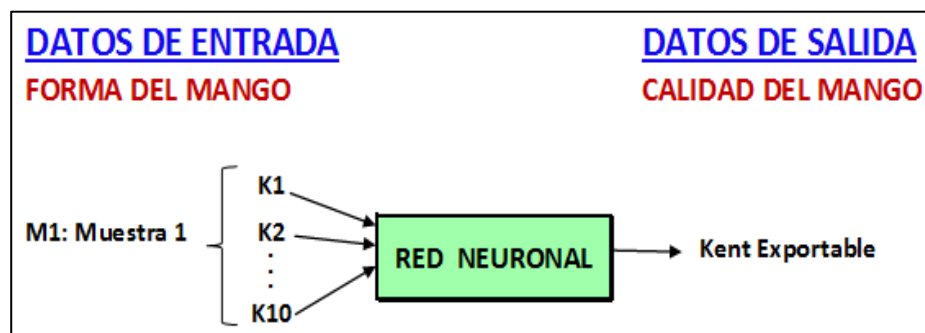


Figura 3.5: Relación entre los Datos de Entrada y Salida para la Muestra M1.

De acuerdo a lo explicado; el problema será generar por cada fruto de mango de la muestra un vector lineal de información que lo represente.

3.6.2 Tomar las Imágenes Digitales de los Elementos de la Muestra

Como se mencionó, la muestra elegida es $M1 = \{K1, K2, K3, K4, \dots K10\}$; que corresponden a los 10 mangos del tipo Kent exportable.

Luego, mediante una cámara digital capturamos las imágenes de los elementos de la muestra que a continuación las mostramos.

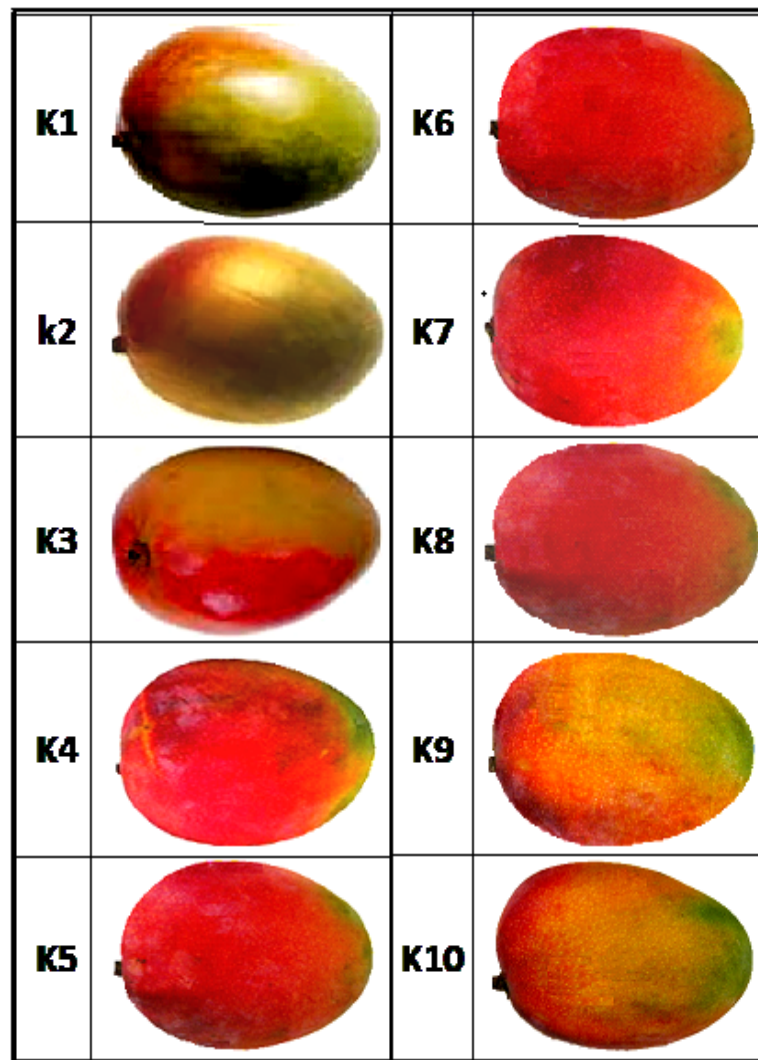


Figura 3.6: Imágenes de los tres Primeros Mangos de la Muestra.

3.6.3 Convertir Imágenes en Datos Binarios

3.6.3.1 Superponer a cada Imagen una Matriz Bidimensional Apropriada.

Luego para cada imagen, definimos la matriz lo suficientemente fina para convertirla en datos procesables por la RNA. Para nuestro caso intentamos con diferentes matrices, y encontramos que la más acertada fue la de dimensión 50 x 50.




Figura 3.7: Imagen de un Mango con una Matriz Asociada.

3.6.3.2 Obtener el Borde de la Imagen en la Matriz Bidimensional

Luego procedemos a obtener el borde de la imagen y representamos dicho borde, usando las celdas de la matriz de 50 x 50, tal como se observa en la secuencia de las siguientes imágenes:




Figura 3.8: Imagen del Borde de un Mango y su Matriz Asociada.

3.6.3.3 Generar Matriz con Información Binaria

Ahora generamos los datos reemplazando las celdas vacías con 0's y las sombreadas con 1's.




Figura 3.9: Matriz con la Información Binaria del Borde de un Mango.

3.6.3.4 Generar Vector Lineal con Información Binaria

Ahora para generar los datos de entrada a la RNA, convertimos la matriz de datos en un vector lineal X de tamaño 2500 (50 x 50).




Figura 3.10: Conversión de la Matriz Binaria en un Vector.

La secuencia completa para el proceso de convertir imágenes en datos binarios de los tres mangos podemos apreciarla en las siguientes imágenes.

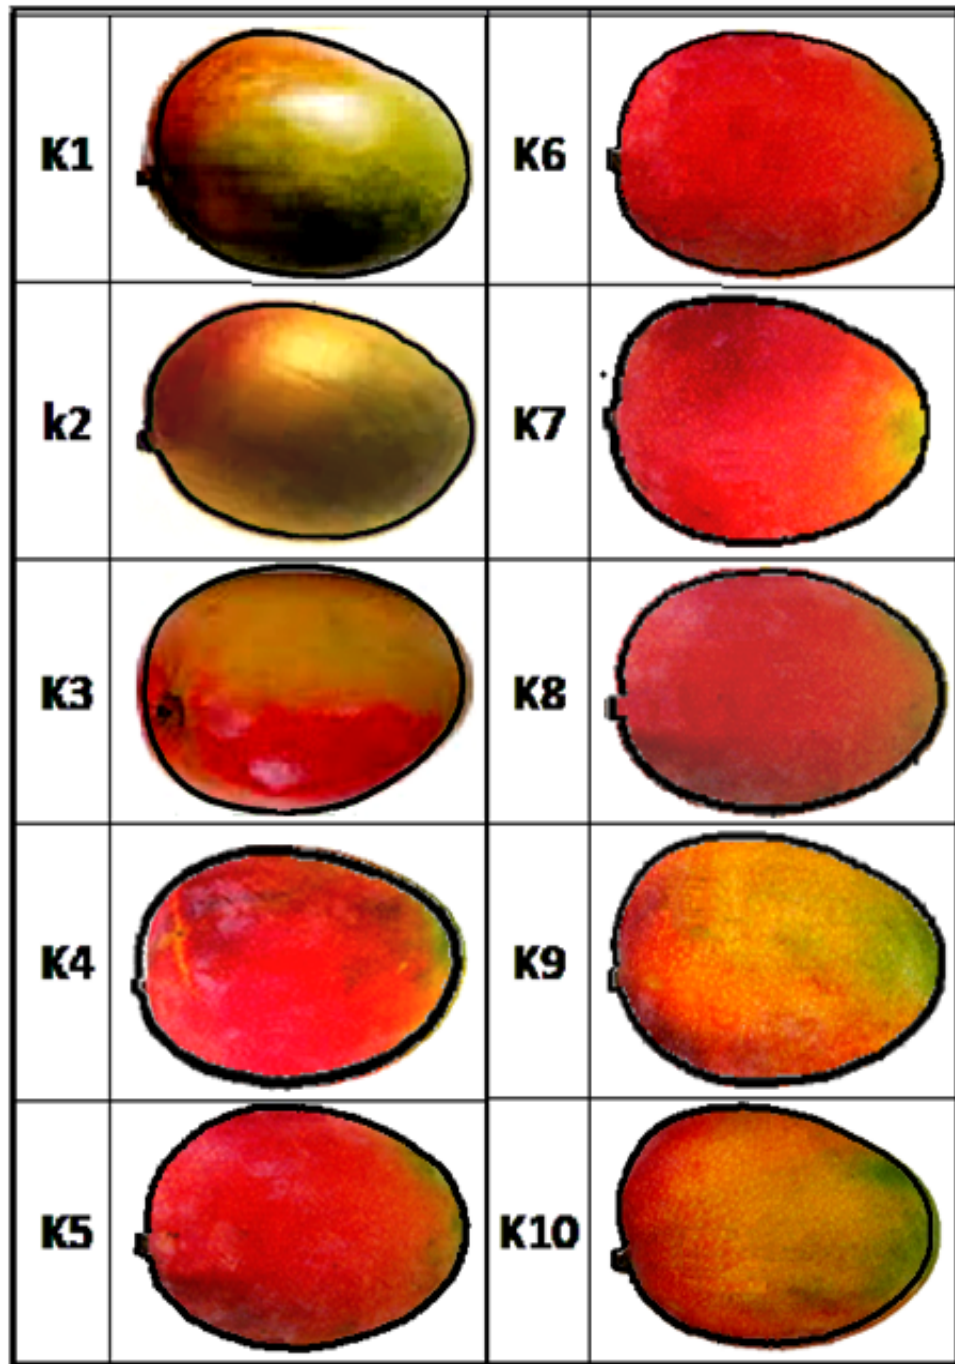


Figura 3.11: Generación de los Bordes de los Mangos de la muestra.

Luego se extraen los bordes de las imágenes.




Figura 3.12: Extracción de los Bordes de los Mangos de la muestra.

Luego se convierten las imágenes de los bordes de cada mango en datos binarios utilizando la matriz binaria asociada como se aprecia en la presente figura.




Figura 3.13: Matriz Asociada para Generar los Datos Binarios de los Bordes de los Mangos.

Apreciemos ahora los 10 bordes de los mangos de la muestra asociados a sus Matrices para la Generación de Datos Binarios.

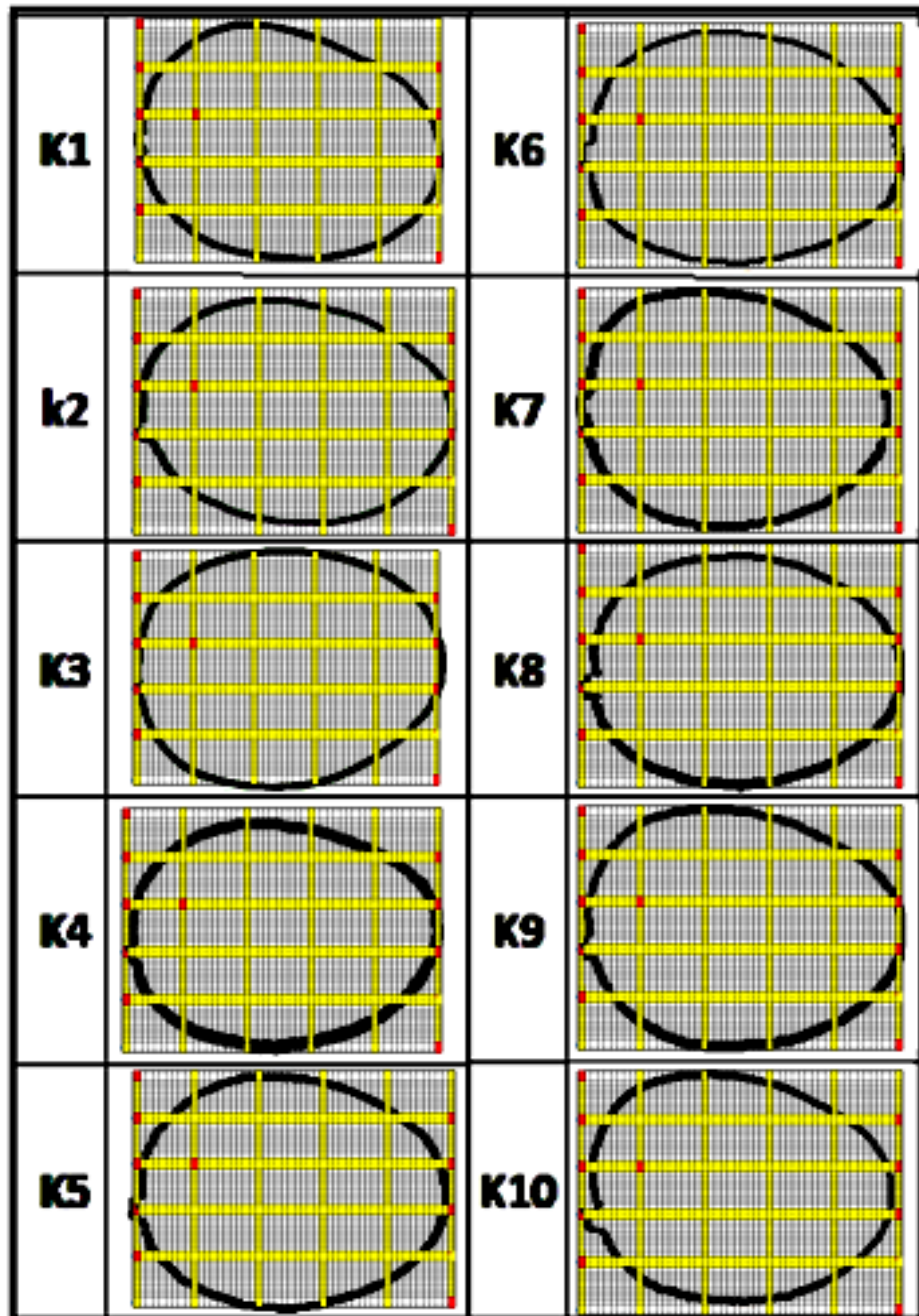


Figura 3.14: Bordes de los Mangos de la Muestra asociada a sus Matrices para Generar los Datos Binarios

3.6.3.5 Almacenar los Vectores Lineales en una Tabla

Como a cada mango le corresponden un vector lineal con 2500 valores binarios, por cuestiones de espacio, mostraremos solamente 10 valores por cada mango, que corresponden a los valores de las celdas resaltadas en rojo en las matrices binarias de las figuras 3.13 y 3.14.

Finalmente, debemos juntar todos los vectores lineales con información binaria, generados por cada mango, en una tabla única que debe contener los vectores lineales de todos los mangos.

En nuestro caso, al juntar los vectores lineales de los 10 mangos tendremos el resultado que se aprecia en la siguiente figura (como mencionamos, por cuestiones de espacio solamente apreciaremos 10 de los 2500 valores de cada vector)

| | X1 | X451 | X500 | X951 | X960 | X1000 | X1451 | X1500 | X1951 | X2500 |
|-----------|----|------|------|------|------|-------|-------|-------|-------|-------|
| Mango K1 | 0 | 0 | 0 | 1 | 0 | 0 | 1 | 1 | 0 | 0 |
| Mango K2 | 0 | 0 | 0 | 1 | 0 | 1 | 1 | 1 | 0 | 0 |
| Mango K3 | 0 | 0 | 0 | 1 | 0 | 1 | 1 | 1 | 0 | 0 |
| Mango K4 | 0 | 0 | 0 | 1 | 0 | 1 | 1 | 0 | 0 | 0 |
| Mango K5 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 0 |
| Mango K6 | 0 | 0 | 0 | 1 | 0 | 0 | 1 | 1 | 0 | 0 |
| Mango K7 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| Mango K8 | 0 | 0 | 0 | 1 | 0 | 1 | 1 | 1 | 0 | 0 |
| Mango K9 | 0 | 0 | 0 | 1 | 0 | 1 | 1 | 1 | 0 | 0 |
| Mango K10 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 0 |

Tabla 3.1: Datos Binarios que corresponden a las Imágenes de los Bordos los Mangos Convertidos en.

Como en realidad se cuentan con tres muestras de 10 mangos cada una, la tabla ha sido completada con los 30 vectores lineales correspondientes a cada uno de los 30 mangos.

3.7 ARQUITECTURA DE LA RN

3.7.1 Número de Neuronas en la Capa de Entrada

Está claro que el vector de entrada X, que almacena la imagen de un mango convertida en datos consta de 2500 valores binarios (0's y 1's), cada elemento del vector lineal de entrada debe ser ingresado a la RNA a través de una neurona, por lo tanto es claro que nuestra red neuronal debe tener 2500 neuronas de entrada.

3.7.2 Número de Neuronas en la Capa de Salida

Cada neurona de salida de una red neuronal sirve para reconocer un patrón diferente, como el objetivo de nuestra investigación es reconocer la calidad morfológica de los tres tipos de mangos de exportación (Kent, Haden y Tommy) entonces debemos tener tres neuronas en la capa de salida.




Figura 3.15: Arquitectura de la RNA para el Reconocimiento de la Calidad Morfológica de los Mangos Exportables.

Desde el punto de vista funcional el vínculo entre nuestra RNA y los datos de entrada y salida será como sigue:




Figura 3.13: Representación Funcional entre la RNA y los Datos de Entrada y Salida para el Reconocimiento de la Calidad de los Mangos de Exportación.

Las capas ocultas y el número de neuronas en ellas se establecen en el mismo proceso de entrenamiento, las sinapsis y pesos sinápticos también se calculan en el entrenamiento.

3.8 GENERAR LOS DATOS DE SALIDA DE LA RNA A PARTIR DE LA MUESTRA SELECCIONADA

De acuerdo a arquitectura definida y especificada en la figura 3.12, y teniendo en cuenta la muestra seleccionada en el numeral 3.5.2, los datos de salida se generan de la siguiente manera:

- Si los datos de entrada corresponden a un mango tipo Kent exportable, entonces el vector de salida (Y1, Y2, Y3) será igual a (1, 0, 0). Como la muestra M1 está conformada por 10 mangos tipo Kent exportable, los datos de salida para cada elemento de M1 será (1, 0, 0).
- Si los datos de entrada corresponden a un mango tipo Haden exportable, entonces el vector de salida (Y1, Y2, Y3) será igual a (0, 1, 0). Como la muestra M2 está conformada por 10 mangos tipo Haden exportable, los datos de salida para cada elemento de M2 será (0, 1, 0).
- De modo similar para la para cada elemento de M3, la salida será (0, 0, 1).
- Si la entrada corresponde a un mango que no es exportable, cualquiera sea el tipo, la salida correspondiente será (0, 0, 0).

3.9 GENERAR LA BASE DE ENTRENAMIENTO DE LA RNA

3.9.1 Representar en una Tabla el Conocimiento de los Expertos en Reconocimiento de Mangos.

La Base de Entrenamiento para la RNA, es la representación del conocimiento que tiene el experto humano, en forma de datos procesables por una computadora. Para nuestra investigación, los expertos en clasificación de mangos de la empresa Biofruit seleccionaron 150 mangos de calidad exportable, 50 por cada tipo de mango, de dicha muestra, los expertos en entrenamiento de RNA seleccionaron tres muestras de 10 unidades por cada tipo de mango. Las tres muestras seleccionadas cuidadosamente por expertos en el entrenamiento de RNA, representan para nuestra investigación el **conocimiento del experto humano** y lo podemos representar sencillamente mediante la siguiente tabla:

| MANGO | CALIDAD | |
|-------|------------------|-----------|
| K1 | KENT EXPORTABLE | Muestra 1 |
| K2 | KENT EXPORTABLE | |
| K3 | KENT EXPORTABLE | |
| K4 | KENT EXPORTABLE | |
| K5 | KENT EXPORTABLE | |
| K6 | KENT EXPORTABLE | |
| K7 | KENT EXPORTABLE | |
| K8 | KENT EXPORTABLE | |
| K9 | KENT EXPORTABLE | |
| K10 | KENT EXPORTABLE | |
| H1 | HADEN EXPORTABLE | Muestra 2 |
| H2 | HADEN EXPORTABLE | |
| H3 | HADEN EXPORTABLE | |
| H4 | HADEN EXPORTABLE | |
| H5 | HADEN EXPORTABLE | |
| H6 | HADEN EXPORTABLE | |
| H7 | HADEN EXPORTABLE | |
| H8 | HADEN EXPORTABLE | |
| H9 | HADEN EXPORTABLE | |
| H10 | HADEN EXPORTABLE | |
| T1 | TOMMY EXPORTABLE | Muestra 3 |
| T2 | TOMMY EXPORTABLE | |
| T3 | TOMMY EXPORTABLE | |
| T4 | TOMMY EXPORTABLE | |
| T5 | TOMMY EXPORTABLE | |
| T6 | TOMMY EXPORTABLE | |
| T7 | TOMMY EXPORTABLE | |
| T8 | TOMMY EXPORTABLE | |
| T9 | TOMMY EXPORTABLE | |
| T10 | TOMMY EXPORTABLE | |

Tabla 3.2: Representación del Conocimiento de Expertos.

3.9.2 Generar la Base de Entrenamiento

Para generar la base de entrenamiento de la RNA se debe transformar la tabla de representación del conocimiento del experto, en datos procesables por el computador.

Como hemos visto los mangos se representan mediante el vector lineal X de 2500 valores binarios, mientras que la calidad de mango se representa mediante el vector Y de 3 valores binarios (por razones de espacio, al igual que los casos anteriores, solamente se mostrarán los tres primeros registros).

| MANGO | CALIDAD | BASE DE CONOCIMIENTO PARA EL ENTRENAMIENTO DE LA RED NEURONAL | | | | | | | | | | | | |
|-------|-----------------|---|------|------|------|------|-------|-------|-------|-------|-------|-----------------|----|----|
| | | Datos de Entrada | | | | | | | | | | Datos de Salida | | |
| | | X1 | X451 | X500 | X951 | X960 | X1000 | X1451 | X1500 | X1951 | X2500 | Y1 | Y2 | Y3 |
| K1 | KENT EXPORTABLE | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 |
| K2 | KENT EXPORTABLE | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 0 | 0 |
| K3 | KENT EXPORTABLE | 0 | 0 | 0 | 1 | 0 | 1 | 0 | 0 | 0 | 0 | 1 | 0 | 0 |
| K4 | KENT EXPORTABLE | | | | | | | | | | | | | |
| K5 | KENT EXPORTABLE | | | | | | | | | | | | | |

Tabla 3.3: Base de Entrenamiento de la RNA.

De ese modo, se generan los datos de entrada y salida para cada uno de los 10 mangos de cada muestra, por lo tanto, para nuestra investigación la Base de Entrenamiento de la RNA tendrá un total de 30 registros.

Finalmente, los datos de este cuadro se guardan en un archivo tipo texto digamos MUESTRAENT.TXT, este archivo será usado con el software de entrenamiento.

3.10 ENTRENAMIENTO DE RNA EN EL RECONOCIMIENTO DE MANGOS

Para entrenar una RNA se debe usar un software, de entre los muchos que existen nosotros usaremos el NEUROTRAINPATTERN.M que está desarrollado en MATLAB cuya funcionalidad se especifica en la siguiente figura:

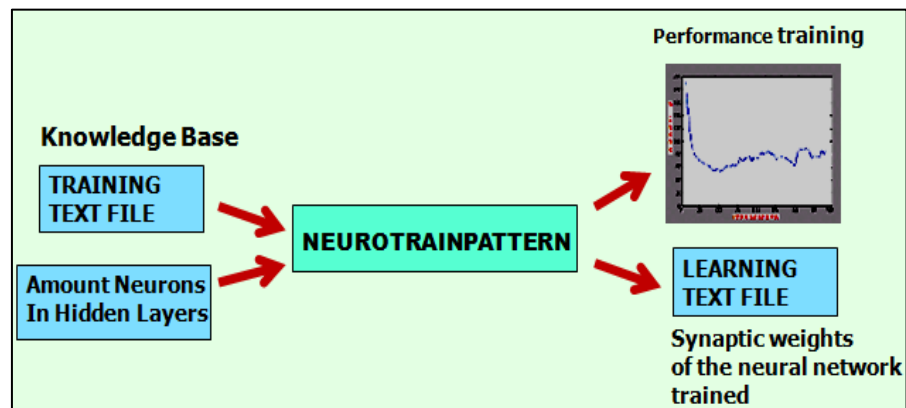


Figura 3.16: Funcionalidad del NEUROTRAINPATTERN.M.

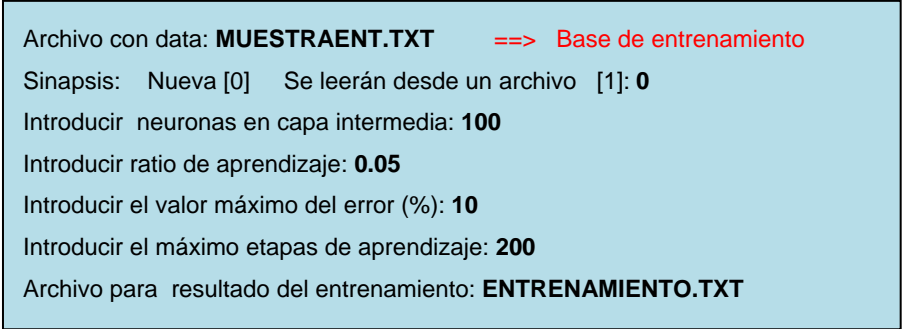
A continuación mostraremos paso a paso el procedimiento de entrenamiento de una RNA utilizando el NEUROTRAINPATTERN.M y nuestra Base de Entrenamiento almacenada en MUESTRAENT.TXT.

En esta etapa de la investigación, se busca una RNA que sea capaz de aprender a reconocer los datos de entrada y vincularlos con los datos de salida. Anteriormente ya hemos definido el número de neuronas de entrada y de salida, por lo tanto, para que la arquitectura de la RNA buscada quede completamente definida, sólo nos falta encontrar el número de neuronas adecuadas de la capa intermedia. **Sin embargo, aunque el funcionamiento de la red depende en forma importante del número de nodos en las capas ocultas, no existe aún un método confiable que permita determinar con precisión el número óptimo de estos [Sánchez04], por lo tanto, la realizaremos de una manera experimental.**

3.10.1 Primer Entrenamiento

3.10.1.1 Ingreso de Parámetros

En el entorno del MATLAB ejecutamos el programa NEUROTRAINPATTERN.M e ingresamos los parámetros requeridos.



```
Archivo con data: MUESTRAENT.TXT ==> Base de entrenamiento
Sinapsis: Nueva [0] Se leerán desde un archivo [1]: 0
Introducir neuronas en capa intermedia: 100
Introducir ratio de aprendizaje: 0.05
Introducir el valor máximo del error (%): 10
Introducir el máximo etapas de aprendizaje: 200
Archivo para resultado del entrenamiento: ENTRENAMIENTO.TXT
```

Figura 3.17: Ingreso de Parámetros en el NEUROTRAINPATTERN.M.

Justificación de los Parámetros Ingresados:

Archivo con Data: MUESTRAENT.TXT

Es el nombre del archivo donde se guardó la base de entrenamiento.

Sinapsis: Nueva [0] / Se leerán desde un archivo [1]: 0

Los pesos sinápticos deben ser generados. El valor 1 se utilizará en la fase de reconocimiento.

Introducir neuronas en capa intermedia: 100

No habiendo fórmulas, elegimos un valor que ha sido usado acertadamente en el reconocimiento de dígitos⁵.

Introducir ratio de aprendizaje: 0.05

Usado acertadamente en el entrenamiento de RNA para reconocimiento de dígitos³.

Introducir el valor máximo del error (%): 20

El algoritmo BACKPROPAGATION en cada iteración ajusta los pesos sinápticos minimizando las diferencias entre los valores

⁵ PhD. Jesús Emeterio Navarro-Barrientos, *RNA para el Reconocimiento de Dígitos*, 2001

calculados por la RNA y los valores esperados, especificados en la Base de Entrenamiento, este proceso se realiza hasta alcanzar el porcentaje especificado en el parámetro ingresado, o hasta realizar una determinada cantidad de iteraciones indicada en el parámetro inmediato siguiente. Es por esta razón, es recomendable iniciar las pruebas con porcentajes de error no muy bajos.

Introducir el máximo etapas de aprendizaje: 200

Por las mismas razones explicadas en el caso anterior, es recomendable iniciar el entrenamiento con valores no muy altos de modo que si no hay convergencia, el proceso termine rápidamente.

Archivo para resultado del entrenamiento: ENTRENAMIENTO.TXT

Es el archivo donde se almacenan los pesos sinápticos generados.

3.10.1.2 Análisis del Resultado

Después del proceso de entrenamiento, el NEUROTRAINPATTERN nos muestra gráficamente el proceso de entrenamiento de la RNA.




Figura 3.18: Curva de Aprendizaje de la RNA - Mal Entrenamiento.

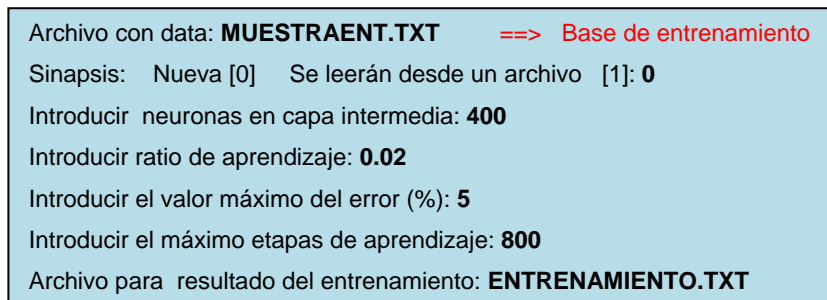
En el gráfico podemos apreciar que la curva descrita nos muestra un proceso inadecuado de aprendizaje ya que según los parámetros ingresados se deseaba alcanzar un margen de error del 20 % en un total máximo de 200 iteraciones. Según el gráfico se han realizado las 200 iteraciones, alcanzando al final de la curva un margen de error del 60%. Así mismo se puede apreciar que aproximadamente en la iteración 120 llegó al 40% de margen error, correspondiente al pico más bajo encontrado y en las iteraciones subsiguientes, en lugar de seguir disminuyendo dicho margen de error, empezó a crecer, de modo muy irregular, por lo tanto, este entrenamiento se considera como no exitoso.

3.10.2 Entrenamiento Óptimo

De manera similar realizamos un total de 33 pruebas de entrenamiento, buscando obtener el entrenamiento más óptimo, cambiando los parámetros de entrada del programa, tal es así que en el entrenamiento número 21 pudimos llegar a los resultados que a continuación mostraremos paso a paso, los entrenamientos del 22 al 33 fueron más deficientes que el 21.

3.10.2.1 Ingreso de Parámetros

En el entorno del MATLAB ejecutamos el NEUROTRAINPATTERN e ingresamos los siguientes parámetros:



```
Archivo con data: MUESTRAENT.TXT ==> Base de entrenamiento
Sinapsis: Nueva [0] Se leerán desde un archivo [1]: 0
Introducir neuronas en capa intermedia: 400
Introducir ratio de aprendizaje: 0.02
Introducir el valor máximo del error (%): 5
Introducir el máximo etapas de aprendizaje: 800
Archivo para resultado del entrenamiento: ENTRENAMIENTO.TXT
```

Figura 3.19: Ingreso de Parámetros Óptimos en el NEUROTRAINPATTERN.M.

3.10.2.2 Análisis del Resultado

Con estos nuevos parámetros, al finalizar el proceso de entrenamiento, el software nos proporcionó la siguiente imagen:




Figura 3.20: Curva de Aprendizaje de la RNA - Buen Entrenamiento.

Como podemos apreciar, la figura esta vez nos muestra que hemos alcanzado aproximadamente el 5% de margen de error en 790 iteraciones. Es decir hemos logrado nuestro objetivo y ahora podemos afirmar que tenemos una RNA bien entrenada para el reconocimiento de la calidad de los mangos exportables.

Debemos tener presente que el entrenamiento concluye guardando en un archivo tipo texto todos los pesos sinápticos de la RNA, nosotros lo hemos guardado en el archivo ENTRENAMIENTO.TXT. Este archivo será utilizado más adelante, cuando veamos el proceso de reconocimiento de la calidad de los mangos.

3.11 PRUEBA DE LA EFICIENCIA DE LA RNA ENTRENADA EN EL RECONOCIMIENTO DE MANGOS EXPORTABLES

3.11.1 Elección de los Mangos a ser Reconocidos

Para el entrenamiento de la RNA hemos utilizado una muestra de 30 mangos de 10 unidades por cada tipo de mango exportable y con dicha muestra hemos conseguido una RNA que ha aprendido a reconocer acertadamente las 30 unidades de la muestra.

Ahora, una vez más, con el objetivo de demostrar paso a paso el procedimiento completo del reconocimiento de patrones tomaremos una muestra de 3 mangos, dos que no cumplen con las características de calidad de exportación y otro que si cumple y verificaremos si la RNA entrenada reconoce dichas características en estos nuevos modelos cuyas imágenes apreciamos a continuación:



Figura 3.21: Imágenes de Mangos para ser Reconocidos por la RNA.

En este caso como es lógico, para cada unidad procesada, la RNA entrenada, al finalizar el proceso de reconocimiento, debe informarnos si se trata de un mango tipo Kent exportable, Haden exportable, Tommy exportable o simplemente no es exportable; por lo tanto, inicialmente diremos que la calidad de los mangos es desconocida, y que la RNA será precisamente quien se encargue de establecerla.

3.11.2 Generar Datos de Reconocimiento

Ahora, para cada imagen de los mangos elegidos para ser reconocidos, se genera su información binaria.




| MANGO | CALIDAD | DATOS BINARIOS DE LOS MANGOS PARA EL RECONOMIENTO DE CALIDAD | | | | | | | | | | | | |
|---|-------------|--|------|------|------|------|-------|-------|-------|-------|-------|-----------------|----|----|
| | | Datos de Entrada | | | | | | | | | | Datos de Salida | | |
|  | Desconocida | X1 | X451 | X500 | X951 | X960 | X1000 | X1451 | X1500 | X1951 | X2500 | Y1 | Y2 | Y3 |
|  | Desconocida | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 0 | 0 | 0 | 0 |
|  | Desconocida | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 |
| | | 0 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |

Tabla 3.4: Datos de Reconocimiento para evaluar la RNA Entrenada.

Debemos tener presente que los valores correspondientes a la variable de salida serán 0's debido a que los mangos respectivos son de calidad desconocida. Los datos binarios generados, que representan a los mangos que van a ser reconocidos, lo guardamos en un archivo tipo texto, por ejemplo, MUESTRAREC.TXT y luego procedemos a usar el NEUROTRAINPATTERN para reconocer la característica de calidad de dichos mangos.

3.11.3 Proceso de Reconocimiento de Mangos Exportables

El proceso de reconocimiento es muy similar al entrenamiento, a continuación lo describimos paso a paso.

Recordemos que el archivo con datos de los mangos a ser reconocidos lo hemos guardado en MUESTRAREC.TXT.

Como ahora realizaremos un reconocimiento (no un entrenamiento) debemos usar la RNA entrenada, por lo tanto recordemos que los pesos sinápticos del entrenamiento, al finalizar el proceso de entrenamiento fueron almacenados en el archivo ENTRENAMIENTO.TXT.

Ahora, en MATLAB ejecutamos el NEUROTRAINPATTERN e ingresamos los parámetros requeridos, según se muestra a continuación.

Archivo con data: **MUESTRAREC.TXT** => Archivo para Reconocimiento
 Sinapsis: Nueva [0] / Se leerán desde un archivo [1]: 1 => Porque Archivo ya Existe
 Archivo con pesos sinápticos de la Red: **ENTRENAMIENTO.TXT**
 Archivo para resultado del Reconocimiento: **RECONOCIMIENTO.TXT**

Figura 3.22: Ingreso de Parámetros para el Reconocimiento de Patrones.

Como se puede apreciar, al concluir el proceso de reconocimiento, el software genera un archivo de salida donde se almacena el resultado del reconocimiento que ha efectuado la RNA.

Al abrir el archivo RECONOCIMIENTO.TXT apreciaremos la siguiente información.

| Y1 | Y2 | Y3 |
|-------|-------|-------|
| 0.341 | 0.294 | 0.307 |
| 0.469 | 0.482 | 0.328 |
| 0.813 | 0.197 | 0.225 |

Tabla 3.5: Información del Archivo de Salida del Proceso de Reconocimiento.

3.11.4 Interpretación de los Datos de Salida

Para interpretar fácilmente los valores del archivo de salida del proceso de reconocimiento primero ponemos los valores del archivo de salida RECONOCIMIENTO.TXT en una tabla, luego con los valores de dicha

tabla reemplazamos los valores respectivos de la tabla de Datos de Reconocimiento presentados en la tabla 3.4.

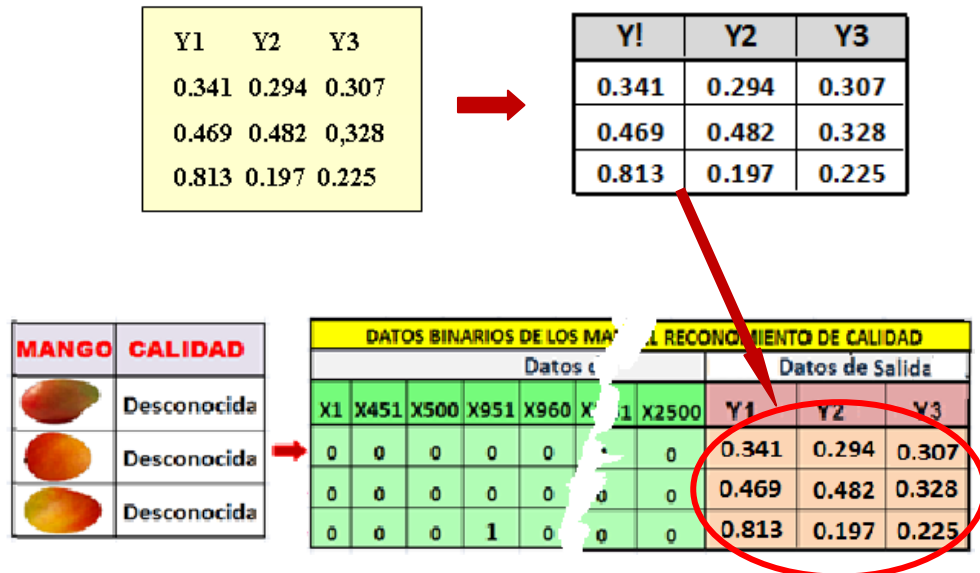


Tabla 3.6: Datos de Entrada y Salida después del Proceso de Reconocimiento.

Recordemos que Y1 está asociada calidad morfológica de mangos tipo Kent, Y2 a mangos del tipo Haden y Y3 a mangos del tipo Tommy. Por lo tanto los valores de salida [Y1, Y2, Y3] proporcionados por el software al concluir el proceso de reconocimiento se interpretan de la siguiente manera:

Para el primer mango [Y1, Y2, Y3] = [0.341, 0.294, 0.307].

- Y1 = 0.341, quiere decir que la calidad morfológica del primer mango es del 34.1% respecto a un mango de calidad exportable tipo Kent, por lo tanto podemos afirmar que no es un mango Kent exportable.
- Y2 = 0.294, también podemos decir que el primer mango tiene un 29.4% de parecido a un mango Haden exportable, luego simplemente podemos concluir que no es Haden exportable.

- $Y3 = 0.507$, el primer mango solamente tiene el 30.7% de similitud a los mangos Tommy exportables, por lo tanto también afirmamos que no es un mango Tommy exportable.

Pasaremos de frente al tercer mango cuyo vector de salida es:

$$[Y1, Y2, Y3] = [0.813, 0.197, 0.225]$$

- $Y1 = 0.813$, quiere decir que la calidad morfológica del tercer mango es del 81.3% respecto a un mango de calidad exportable tipo Kent, por lo tanto podemos afirmar que es un mango **Kent exportable**, si se aprecia la figura del tercer mango podemos comprobar la eficiencia de la RNA.
- $Y2 = 0.197$, el tercer mango no es un mango Haden exportable.
- $Y3 = 0.225$, el tercer mango no es un mango Tommy exportable.

En general:

Si $Y1 > 0.5$, el mango ha sido reconocido como un mango Kent exportable.

Si $Y2 > 0.5$, el mango ha sido reconocido como un mango Haden exportable.

Si $Y3 > 0.5$, el mango ha sido reconocido como un mango Tommy exportable.

En otro caso, significa que el mango ha sido reconocido como un mango No Exportable.

Podemos concluir que nuestra RNA ha reconocido correctamente los tres mangos, los dos primeros los ha reconocido como No Exportable y el tercer mango como Kent Exportable, tal como se esperaba.

CAPÍTULO IV

SISTEMA EXPERTO PARA RECONOCER MANGOS EXPORTABLES USANDO RNA

4.1 DESCRIPCIÓN DEL SISTEMA

Para culminar nuestro proyecto hemos desarrollado un sistema experto para reconocer la calidad morfológica de los mangos exportables utilizando RNA. Este sistema ha sido implementado en Java permite realizar en forma ordenada y secuencial, todos los procesos descritos anteriormente. Mediante el uso de este sistema se pueden realizar los siguientes procesos: ingresar la muestra de mangos exportables obteniendo y almacenando las imágenes de cada mango, generar los bordes los mangos, generar los datos de entrenamiento, buscar la RNA apropiada que reconozca los elementos de la muestra, procesar el entrenamiento de la RNA, ingresar las imágenes de los mangos para realizar la prueba de reconocimiento, realizar el reconocimiento de los mangos ingresados, interpretar los resultados del reconocimiento.

Otro detalle importante es que, el sistema, realiza automáticamente el registro histórico de toda la información procesada, de modo que también permite generar reportes estadísticos.

Finalmente, la rapidez y precisión del sistema permite identificar instantáneamente el nivel de perfección morfológica de los mangos exportables dándoles el atributo de A1 a los mangos cuyo porcentaje de similitud con los patrones de la muestra es superior al 80%; A2 si está entre un 70% y 80%; A3 si está entre 60% y 70%. Si el porcentaje de similitud con los patrones es menor al 60% se dirá que un mango es NO EXPORTABLE.

4.2 MÓDULOS DEL SISTEMA

4.2.1 Módulo para Fijar Parámetros de Binarización de Imágenes

Permite definir el tamaño de la matriz y el tipo de binarización; éstos son los parámetros con los cuales se generará la información binaria en base a la imagen de cada uno de los elementos de la muestra.

4.2.2 Módulo de Entrenamiento de la RNA

Permite capturar las imágenes de los mangos de la muestra, generar la base de entrenamiento y finalmente realizar entrenamientos de la RNA consecutivamente hasta conseguir una RNA que reconozca a todos los mangos exportables de la muestra.

4.2.3 Módulo de Reconocimiento de Mangos Exportables

Permite capturar las imágenes de los mangos cuya calidad se desea reconocer, e inmediatamente se genera un registro en la tabla de resultados de reconocimientos con un indicador de reconocimiento, si un mango es reconocido como un mango exportable se especifica el tipo Kent, Haden o Tommy y la clase del mismo en función a la similitud con el patrón de la muestra A1, A2 o A3 según lo explicado en el numeral 4.1. Si un mango no es reconocido como exportable tendrá como indicador NO EXPORTABLE. Toda la información procesada es almacenada, automáticamente, por el sistema en su base de datos, acondicionada especialmente para este propósito.

4.2.4 Módulo de Estadísticas de Reconocimientos de Mangos

Permite generar reportes estadísticos respecto a los procesos de reconocimiento históricos, almacenados en su Base de Datos.

4.3 PRUEBA DE FUNCIONAMIENTO DEL SISTEMA EXPERTO

4.3.1 Módulo para Fijar Parámetros de Binarización de Imágenes

Nos permite especificar las dimensiones de la matriz apropiada para representar las imágenes deseadas, para el caso de los mangos, como explicamos en el numeral 3.6.3, la dimensión adecuada es de 50 filas x 50 columnas.

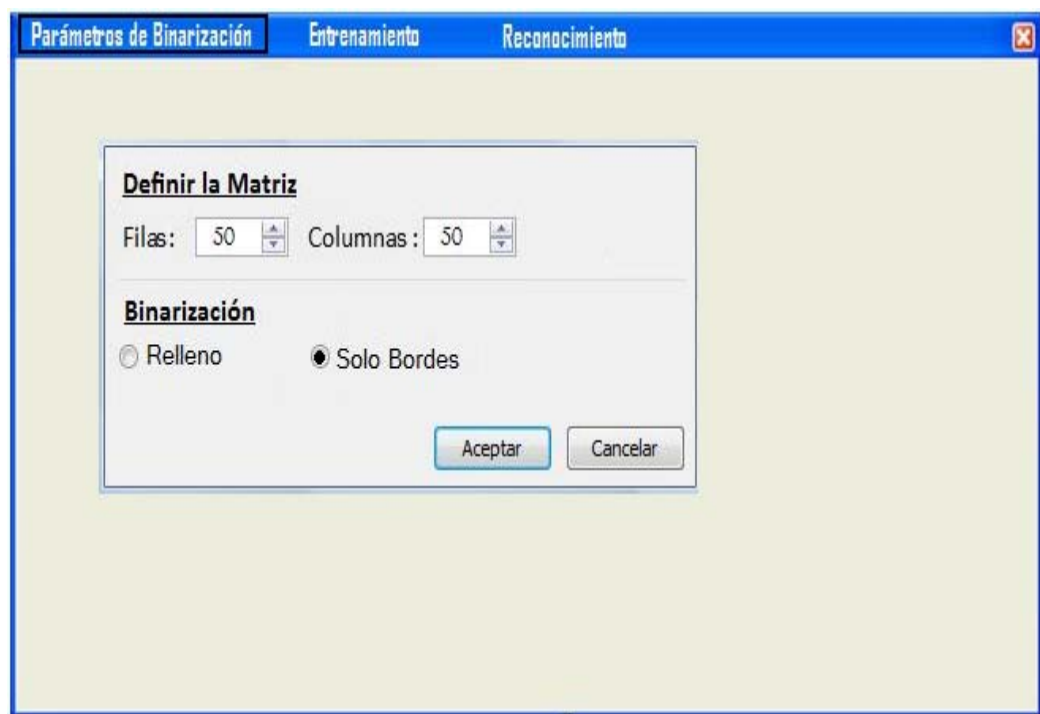


Figura 4.1: Módulo para el ingreso de los Parámetros de Binarización.

Como se va a trabajar solamente los bordes de las imágenes de los mangos, en la opción Binarización, seleccionamos la opción correspondiente y luego aceptamos y salimos.

4.3.2 Módulo de Entrenamiento de la RNA

Capturamos las imágenes de los mangos de la muestra cuyo detalle se precisó en el numeral 3.5.2.

Parámetros de Binarización Entrenamiento Reconocimiento

Imagen en Linea Imagen

Capturar

Tipo de Mango
KENT

Aceptar

Lista de Muestras

| | Imagen | Tamaño kb | Fecha |
|----|---------------|-----------|------------------|
| 1 | Kent 001 .jpg | 9 | 30/07/2010 09:13 |
| 2 | Kent 002 .jpg | 11 | 30/07/2010 09:13 |
| 3 | Kent 003 .jpg | 7 | 30/07/2010 09:14 |
| 4 | Kent 004 .jpg | 13 | 30/07/2010 09:15 |
| 5 | Kent 005 .jpg | 12 | 30/07/2010 09:16 |
| 6 | Kent 006 .jpg | 15 | 30/07/2010 09:17 |
| 7 | Kent 007 .jpg | 11 | 30/07/2010 09:18 |
| 8 | Kent 008 .jpg | 8 | 30/07/2010 09:19 |
| 9 | Kent 009 .jpg | 8 | 30/07/2010 09:19 |
| 10 | Kent 010 .jpg | 12 | 30/07/2010 09:20 |

Crear Base de Entrenamiento

Entrenar RNA Y Crear la Base de Conocimientos

Figura 4.2: Captura de Imágenes para el Entrenamiento de la RNA.

El nombre, tamaño y fecha de cada imagen se va registrando en la tabla de muestras. Al concluir con el ingreso de los elementos de la muestra con el botón rotulado “Crear Base de Entrenamiento” se genera precisamente la **Base de Entrenamiento** que como vimos en la tabla 3.3, consiste en el conjunto de datos binarios que se generan por cada imagen; el sistema pedirá el nombre del archivo texto donde se guardará esta información para nuestro caso le damos **MUESTRAENT.TXT**.

Luego, seleccionamos el botón rotulado “Entrenar RNA y Crear la Base de Conocimiento” e ingresamos los parámetros solicitados. El proceso de entrenamiento genera como resultado la gráfica de la curva de aprendizaje en R2 como se puede apreciar en la imagen adjunta. Si en el resultado se observa un entrenamiento inadecuado se debe realizar otro entrenamiento, cambiando los parámetros de entrenamiento hasta conseguir un resultado adecuado.

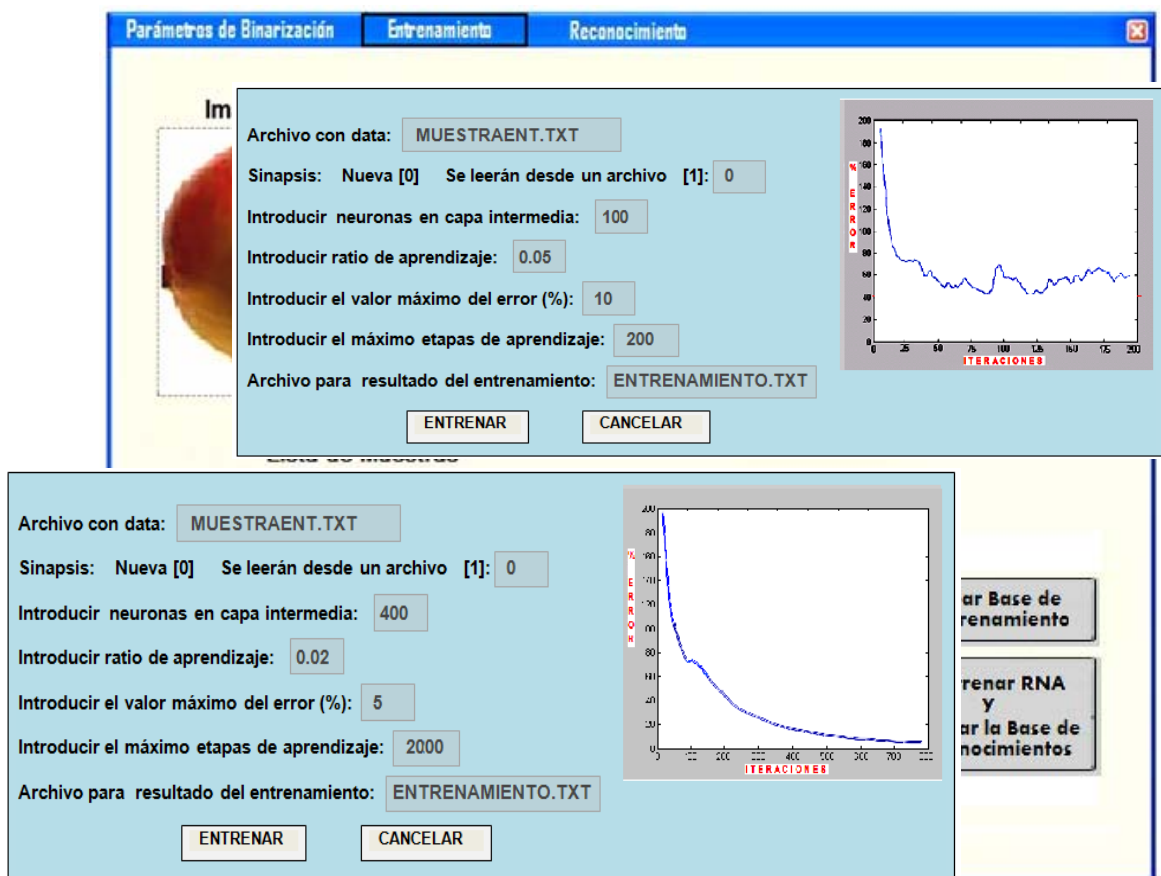


Figura 4.3: Módulo de Entrenamiento de la Red Neuronal.

Como se puede apreciar, uno de los parámetros del entrenamiento es el “Archivo para resultados del Entrenamiento”, en nuestro caso es ENTRENAMIENTO.TXT, en dicho archivo se guardan los pesos sinápticos calculados en el proceso de entrenamiento de la RNA; dicha información la conoceremos como **Base de Conocimientos de la RNA**.

4.3.3 Módulo de Reconocimiento de Mangos Exportables

El sistema permite, capturar las imágenes de los mangos cuya calidad se desea reconocer. Al ingresar la imagen de un mango inmediatamente se procede con el reconocimiento para dicho mango y en la tabla adjunta se registra los resultados del reconocimiento por cada mango, tal como se aprecia en la imagen adjunta.

Imagen en Linea

Imagen

Capturar

Aceptar

RESULTADO DE RECONOCIMIENTOS DE LA CALIDAD DE LOS MANGOS

| | Imagen | Fecha | Calidad |
|----|---------|------------------|---------------|
| 9 | Img0010 | 20/08/2010 09:27 | Kent A1 |
| 10 | Img0011 | 20/08/2010 09:27 | Kent A2 |
| 11 | Img0012 | 20/08/2010 09:27 | Kent A2 |
| 12 | Img0013 | 20/08/2010 09:27 | Kent A2 |
| 13 | Img0014 | 20/08/2010 09:28 | Kent A1 |
| 14 | Img0015 | 20/08/2010 09:28 | Kent A1 |
| 15 | Img0016 | 20/08/2010 09:28 | Kent A1 |
| 16 | Img0017 | 20/08/2010 09:28 | No Exportable |
| 17 | Img0018 | 20/08/2010 09:29 | Kent A2 |
| 18 | Img0019 | 20/08/2010 09:29 | No Exportable |

GUARDAR

Figura 4.4: Módulo de Reconocimiento de Mangos.

En esta prueba se ha realizado el reconocimiento de 18 mangos de los cuales 16 han sido reconocidos como mangos exportables tipo Kent y dos mangos como No Exportables, se puede apreciar que cada registro consta del nombre de la imagen, la fecha y hora que fue capturada la imagen, y el resultado del reconocimiento. Existe una carpeta de imágenes donde se

guardan todas las imágenes que son ingresadas, las mismas que pueden ser accedidas con el nombre, fecha y hora de su registro.

Al finalizar un proceso de reconocimiento, la información completa de dicho proceso puede ser guardada en la base de datos del sistema con un nombre elegido por el usuario, en nuestro caso, supongamos que los 18 registros procesados los guardamos con el nombre DEMO-REC, este nombre es registrado con la fecha y hora del sistema.

4.3.4 Módulo de Estadísticas de Reconocimientos de Mangos

En el presente módulo procedemos a generar los gráficos estadísticos de los resultados de reconocimientos previamente guardados.

En el paso anterior guardamos el proceso de reconocimiento con el nombre DEMO-REC con fecha 20/08/2010, por lo tanto si generamos las estadísticas para dicha fecha tendremos el siguiente resultado:




Figura 4.5: Resultados Obtenidos por el Sistema Experto basado en RNA.

4.4 CLASIFICACIÓN DE MANGOS CON EL SISTEMA EXPERTO, PARA LA PRUEBA DE LA HIPÓTESIS

4.4.1 Muestra de Mangos para ser Clasificados por el Sistema Experto

Para probar nuestra hipótesis, apoyados por dos expertos de la compañía Biofruit, y expertos en reconocimiento de patrones con RNA, tomamos tres grupos de mangos del tipo Kent de 100 unidades cada grupo.

4.4.2 Datos Generados por Expertos

Los 300 mangos, fueron cuidadosamente revisados y validados por los expertos, quienes proporcionaron el siguiente resultado:

| EXPERTOS | Grupo 1 | Grupo 2 | Grupo 3 |
|-------------|---------|---------|---------|
| TOTAL | 100 | 100 | 100 |
| Exportables | 77 | 68 | 91 |
| Deformes | 23 | 32 | 9 |

Tabla 4.1: Muestra Clasificada por Expertos de Biofruit.

Luego, cada mango fue marcado como Exportable o Deforme, según dichos resultados, las marcas de testeo fueron señales imperceptibles a simple vista.

4.4.3 Datos Proporcionados por el Personal Asignado al Proceso de Clasificación

A continuación, solicitamos al personal asignado al proceso de clasificación que realice el proceso de selección de los 300 mangos en condiciones normales. Al terminar el proceso de selección los resultados fueron los siguientes:

| CLASIFICADORES | Grupo 1 | Grupo 2 | Grupo 3 |
|----------------|---------|---------|---------|
| TOTAL | 100 | 100 | 100 |
| Exportables | 63 | 55 | 82 |
| Deformes | 37 | 45 | 18 |

Tabla 4.2: Clasificación Realizada por el Personal de Biofruit.

Luego, se revisaron las marcas de testeo a todos los mangos clasificados como exportables y se obtuvieron los siguientes resultados:

| CLASIFICADORES | Grupo 1 | Grupo 2 | Grupo 3 |
|-------------------------------|--------------------------------|----------------|--------------------------------|
| Clasificados Como Exportables | 63 | 55 | 82 |
| Informacion Real | 60 Exportables + 3 Deformes | 55 Exportables | 77 Exportables + 5 Deformes |

Tabla 4.3: Errores en la Clasificación Realizada por el Personal de Biofruit

Según las tablas 4.1 y 4.3, de los 100 mangos del Grupo1, 77 fueron reconocidos como exportables y marcados como tales por los expertos. El personal de clasificación de mangos de Biofruit reconoció correctamente sólo 60 y los 17 restantes los reconoció, erradamente, como deformes. Así mismo 3 mangos marcados como deformes fueron reconocidos como exportables. En conclusión la cantidad total de mangos reconocidos erradamente estarían conformados por los mangos exportables reconocidos como deformes más los mangos deformes reconocidos como exportables es decir $17 + 3 = 20$ mangos, tal como podemos apreciarlo en la siguiente figura:

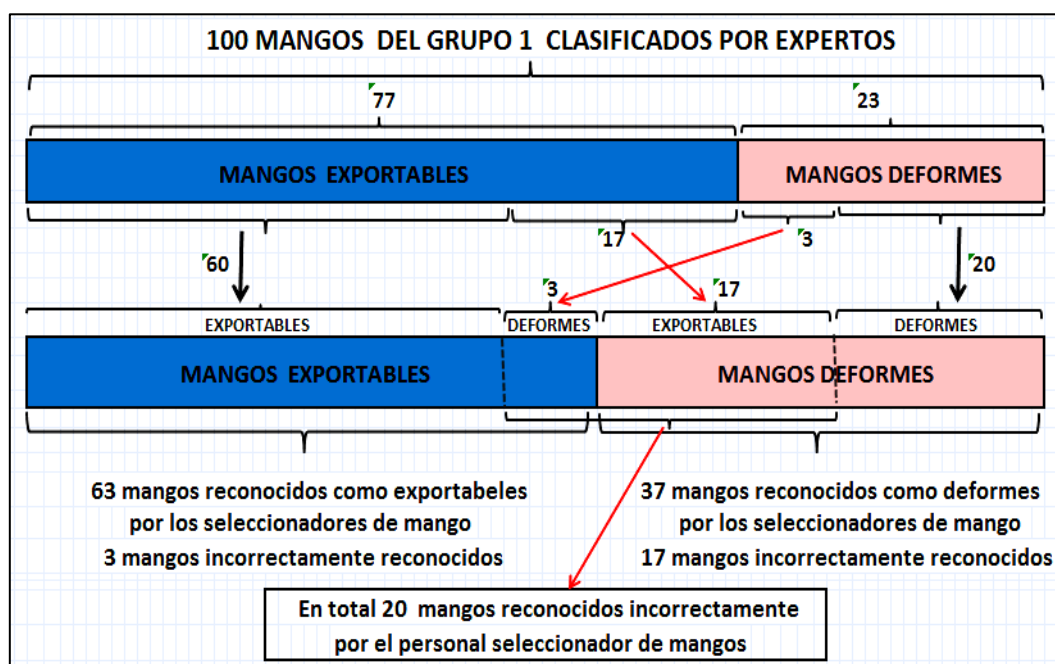


Figura 4.6: Detalles de los Errores de la Clasificación del Personal de Biofruit.

4.4.4 Datos Proporcionados por el Sistema Experto

Utilizando nuestro sistema experto, procedimos a realizar el reconocimiento de las 100 unidades de cada grupo. Los resultados fueron guardados como GRUPO1, GRUPO2 y GRUPO3, todos con fecha 20/08/2010.

En módulo de Estadísticas de Reconocimiento del SE, generamos las estadísticas para el día 20/08/2010 y pudimos apreciar el siguiente resultado:




Figura 4.7: Resultados del Sistema Experto basado en Redes Neuronales.

En el cuadro se puede apreciar el resultado de la demostración de reconocimiento inicial guardado como DEMO-REC, como también los resultados de reconocimiento por cada uno de los tres grupos analizados. Transformando los resultados gráficos de cada grupo en una tabla numérica, se tendría el siguiente resultado:

| SISTEMA EXPERTO | Grupo 1 | Grupo 2 | Grupo 3 |
|-------------------|---------|---------|---------|
| Total Mangos | 100 | 100 | 100 |
| Mangos de Calidad | 75 | 65 | 89 |
| Deformes | 25 | 35 | 11 |

Tabla 4.4: Clasificación Generada Automáticamente por el Sistema Experto.

CAPÍTULO V

ANÁLISIS DE RESULTADOS

5.1 RESUMEN DE LOS RESULTADOS DE CLASIFICACIÓN

Como apreciamos en el numeral 4.4 los procesos de clasificación fueron realizados por:

- Expertos Humanos,
- Clasificadores de la empresa Biofruit y el
- Sistema Experto

El presente cuadro comparativo, tomando como referencia las tablas 4.1, 4.2, 4.3 y 4.4, muestra por cada grupo de 100 unidades, la cantidad de mangos considerados como exportables por cada agente de selección.

| AGENTE SELECCIONADOR | Grupo 1 (100 Mangos) | Grupo 2 (100 Mangos) | Grupo 3 (100 Mangos) |
|------------------------|----------------------|----------------------|----------------------|
| EXPERTO HUMANO | 77 | 68 | 91 |
| CLASIFICADORES | 63 = 60 + 3 | 55 | 82 = 77 + 5 |
| SISTEMA EXPERTO | 75 | 65 | 89 |

Tabla 5.1: Número de Mangos Considerados como Exportables por los Diferentes Agentes de Selección.

Gráficamente, estas cifras se apreciarían de la siguiente manera:




Figura 5.1: Cuadro Comparativo de los Resultados de Selección.

Como se puede apreciar, para los tres grupos, las diferencias entre la cantidad de mangos clasificados como exportables por los Expertos Humanos y los clasificadores son considerablemente mayores que las diferencias generadas por los Expertos Humanos y Sistema Experto.

5.2 ANÁLISIS COMPARATIVO DE LOS RESULTADOS DE CLASIFICACIÓN, PRUEBA DE LA HIPÓTESIS

A continuación presentamos el análisis comparativo de las cifras

| | Mangos Analizados | EH | C L | | SE | Error Parcial de CL | | Error Total de CL | | Error del SE | |
|---------|----------------------|----------|----------------|---------|---------|---------------------|--------|-------------------|--------|--------------|-------|
| | | Expertos | Clasificadores | | Sistema | | | (EH - CL) + | | | |
| | | Humanos | Validos | Errados | Experto | EH - CL(Valido) | (%) | CL(Errado) | (%) | EH - SE | (%) |
| Grupo 1 | 100 | 77 | 60 | 3 | 75 | 17 | 17.00% | 20 | 20.00% | 2 | 2.00% |
| Grupo 2 | 100 | 68 | 55 | 0 | 65 | 13 | 13.00% | 13 | 13.00% | 3 | 3.00% |
| Grupo 3 | 100 | 91 | 77 | 5 | 89 | 14 | 14.00% | 19 | 19.00% | 2 | 2.00% |
| Total | 300 | 236 | 192 | 8 | 229 | 44 | 14.67% | 52 | 17.33% | 7 | 2.33% |

Tabla 5.2: Detalle Comparativo de los Resultados de la Selección.

Del análisis comparativo de la información de la tabla 5.2 podemos concluir que el margen de error promedio de los clasificadores de mango de la empresa Biofruit es del 17.33 %, mientras que el margen de error promedio del Sistema Experto es del 2.33 %.

Por los resultados obtenidos, podemos afirmar que el sistema experto que hemos desarrollado permite reconocer y clasificar los mangos exportables según su morfología con un margen de error del 2.33 %.

CAPÍTULO VI

CONCLUSIONES Y RECOMENDACIONES

6.1 CONCLUSIONES

- Al finalizar el presente trabajo, podemos concluir que con un Sistema Experto basado en RNA, la empresa Biofruit puede realizar la clasificación de mangos exportables con un margen de error de 2.33%. El margen de error del personal de clasificación de mangos es de 17.3%, lo que quiere decir que se ha logrado una optimización del 15 %.
- Respecto al patrón morfológico de un mango, concluimos que el contorno o borde de su imagen, generado por el software, es un patrón apropiado para entrenar adecuadamente una RNA.
- El diseño de la RNA que ha sido capaz de aprender a reconocer los 30 mangos de la muestra tiene la siguiente configuración: 2500 neuronas en la capa de entrada (para tomar como entrada de la RNA el borde de la imagen de un mango), 3 neuronas en la capa de salida (para que la RNA pueda identificar tres tipos de mangos exportables) y 400 neuronas en la capa oculta (para que pueda realizar un entrenamiento adecuado).
- El Sistema Experto basado en RNA que hemos implementado permite automatizar los procesos de entrenamiento de las RNA y los procesos de reconocimiento de mangos, así como el registro histórico de todos los procesos y la generación de reportes estadísticos.

6.2 RECOMENDACIONES

- Recomendamos el uso del modelo Perceptrón multicapa para el reconocimiento de patrones ya que se pueden lograr resultados con márgenes de error muy pequeños.
- Así mismo cuando se trata de imágenes sólidas, se recomienda trabajar con los bordes de dichas imágenes, debido que el reconocimiento de patrones se basa en un porcentaje de equivalencias entre los patrones o imágenes modelo con las formas que se desea reconocer.
- Se recomienda tener el máximo cuidado en elegir la muestra de entrenamiento ya que de ello depende el éxito del entrenamiento de la RNA.

REFERENCIAS BIBLIOGRÁFICAS

Libros y Revistas

- [Anderson95] J. Anderson. *An Introduction to Neural Networks*. USA: MIT Press, 1995.
- [Betancourt10] L. Betancourt, W. Cuervo, J. López, A. Orjuela. *Calidad*. Bogotá: Servicio Nacional De Aprendizaje Sena, 2010.
- [Bishop96] C. Bishop. *Neural Networks for Pattern Recognition*. USA: Oxford University Press, 1996.
- [Bonta02] K. Bonta, M. Farber. 02. *Preguntas Sobre Marketing y Publicidad*. Bogota: Norma, 2002.
- [Castellano98] M. Castellano. *Calidad Total*. México: La Prensa Médica, 1998.
- [Charytoniuk00] W. Charytoniuk. *Neural Network Based demand forecasting in a deregulated environment*. Industry Applications, IEEE Transactions on, Volumen 36, serie 3, páginas 893-898, 2000.
- [Duda01] R. Duda, P. Hart, D. Stork. *Pattern Classification*. New York: Wiley, 2001.
- [Flores06] R. Flórez, J. Fernández. *Las Redes Neuronales Artificiales: Fundamentos Teóricos y Aplicaciones Prácticas*. España: Netbiblo, 2006.
- [Freeman91] J. Freeman, D. Skapura. *Neural Networks - Algorithms, Applications and Programming Techniques*. Willington: Adison Wesley, 1991.
- [García05] A. García, S. Boria. *Los Nuevos Emprendedores: Creación de Empresas en el Siglo XXI*. Barcelona: Universitat Barcelona, 2005.
- [Hilera95] J. Hilera, V. Martínez. *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones*. Madrid: Alfaomega, 1995.
- [Martin07] B. Martin, A. Sanz. *Redes Neuronales y Sistemas Borrosos*. Madrid: Alfaomega, 2007.
- [Montaño02] J. Montaño, *Redes Neuronales Aplicadas al análisis de datos*. Tesis Doctoral, Palma de Mallorca, 2002.
- [Pino01] R. Pino, A. Gómez, N. Abajo. *Introducción a la Inteligencia Artificial: Sistemas Expertos, Redes Neuronales Artificiales y Computación Evolutiva*. España: Universidad de Oviedo, 2001.
- [Stanton07] W. Stanton, M. Etzel y B. Walker. *Fundamentos de Marketing*. México: McGraw Hill, 2007.
- [Swingler96] K. Swingler. *Applying Neural Networks: A Practical Guide*. Inglaterra: Morgan Kaufman, 1996.
- [Sánchez04] G. Sánchez, H. Pérez, M. Nakano. *Red Neuronal Creciente Usando Perturbación Simultánea*. Información Tecnológica, Volumen 15, serie 5, páginas 45-52, 2004.

Citas Electrónicas en Internet:

- [W-Agrobanco07] Agro Banco - Área de Desarrollo. **Cultivo del Mango**.
En: www.agrobanco.com.pe/cultivo_del_mango.pdf
Consultado 6-Jul-2010.
- [W-Andina10] Agencia Peruana de Noticias. **Exportaciones No Tradicionales**.
En: www.andina.com.pe/Espanol/especiales/style2/HomeStyle2.aspx?Proceso=37
Consultado 8-May-2010.
- [W-Ccpa10] Cámara de Comercio Peruano Australiana. **Economía del Perú**.
En: www.ccpa.org.pe/?page=05_03peru-economy&lang=es
Consultado 19-Jun-2010..
- [W-Concha07] R. Concha. **¿En qué Consiste una Exportación?**.
En: www.icesi.edu.co/agenciadeprensa/contenido/pdfs/icecomex_25_ene.pdf
Consultado 8-May-2010.
- [W-Eufic10] European Food Information Council. **Codex Alimentarius**.
En: www.codexalimentarius.net/web/index_es.jsp
Consultado 19-Jun-2010.
- [W-Kuyeng07] J. Kuyeng. **Exportando Paso a Paso**.
En: www.sanmartinexports.com/exportando_paso_a_paso123.ppsx
Consultado 6-Jul-2010.
- [W-Mincetur10] Ministerio de Comercio Exterior y Turismo. **Perfil del Mercado y Competitividad Exportadora de Mango**.
En: www.mincetur.gob.pe/comercio/otros/penx/pdfs/Mango.pdf
Consultado 19-Oct-2010.
- [W-Onucodex93] Organización de las Naciones Unidas para la Agricultura y la Alimentación. **Norma del Codex para el Mango (CODEX STAN 184-1993)**.
En: www.codexalimentarius.net/download/standards/315/CXS_184s.pdf
Consultado 6-Jul-2010.
- [W-Pérez10] M. Pérez. **Perú: País abierto y competitivo. Exterior del MINCETUR**.
En: www.viverolosvinedos.com/web_v/exposicion_ministro.ppt
Consultado 17-Abr-2010.
- [W-Proinversion10] Proinversión. **Principales Destinos de Exportación**.
En: www.proinversion.gob.pe/0/0/modulos/JER/PlantillaStandardsinHijos.aspx?ARE=0&PFL=0&JER=68
Consultado 6-Jul-2010.
- [W-Senasa02] Servicio Nacional de Sanidad Agraria. **Norma Técnica Peruana - NTP 011.010 2002**.
En: www.senasa.gob.pe/servicios/productor_agropecuario/agricultor/ntp_011.010_mango.pdf
Consultado 6-Jul-2010.
- [W-Siisex10] Sistema Integrado de Información de Comercio Exterior. **Perú: Principales Frutas de Agro Exportación**.
En: www.siicex.gob.pe/siicex/documentosportal/1607029rad902C3.pdf
Consultado 17-Abr-2010.

ANEXOS

Anexo A:

MATRIZ DE CONSISTENCIA

Reconocimiento de la Calidad Morfológica de Mangos Exportables mediante Redes Neuronales para la empresa Biofruit.

| PROBLEMA | OBJETIVOS | HIPÓTESIS | VARIABLES | INDICADORES |
|---|---|---|---|--|
| <p>Problema General ¿De qué manera la empresa Biofruit puede reducir su margen de error en el reconocimiento de la calidad morfológica de mangos exportables del 20% a menos del 5%?</p> <p>Problema Específico 1: ¿De qué manera se generan los patrones morfológicos que identifican a los mangos exportables?</p> <p>Problema Específico 2: ¿De qué manera se diseña una RNA para que reconozca los patrones morfológicos de mangos exportables?</p> <p>Problema Específico 3: ¿De qué manera las Redes Neuronales permiten el Reconocimiento de la Calidad Morfológica de mangos exportables?</p> | <p>Objetivo General Desarrollar un Sistema Experto basado en Redes Neuronales que sea capaz de reconocer los mangos de exportación con un margen de error menor del 5% en la empresa Biofruit.</p> <p>Objetivos Específico 1: Explicar de qué manera se generan los patrones morfológicos que identifican a los mangos exportables.</p> <p>Objetivos Específico 2: Explicar de qué manera se diseña una RNA para que reconozca los patrones morfológicos de mangos exportables.</p> <p>Objetivos Específico 3: Explicar de qué manera las Redes Neuronales permite el Reconocimiento de la Calidad Morfológica de mangos exportables.</p> | <p>Hipótesis General Un Sistema Experto basado en Redes Neuronales puede reconocer la calidad morfológica de mangos exportables con un margen de error menor al 5%</p> | <p>V. Independientes Sistema Experto basado en Redes Neuronales</p> <p>V. Dependientes Reconocimiento de la Calidad Morfológica de los mangos exportables</p> | <p>Independientes</p> <ul style="list-style-type: none"> • Uso de S.E. (Sí , No) <p>I. Dependientes</p> <ul style="list-style-type: none"> • Margen de error (%) |

Anexo C:

**NORMA DEL CODEX PARA EL MANGO
(CODEX STAN 184-1993)**